


ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO FIN DE GRADO

Estimación del estado de salud de la vegetación en ecosistemas vulnerables mediante imágenes hiperespectrales de teledetección


Titulación: Grado en Ingeniería en Tecnologías de la Telecomunicación

Autor: D. Manuel Domínguez Calvo

Tutores: D. Javier Marcello Ruiz
D. Dionisio Rodríguez Esparragón

Fecha: Enero de 2020

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO FIN DE GRADO

**Estimación del estado de salud de la vegetación en
ecosistemas vulnerables mediante imágenes
hiperespectrales de teledetección**

HOJA DE EVALUACIÓN

Calificación: _____

Presidente

Fdo.:

Vocal

Secretario/a

Fdo.:

Fdo.:

Fecha: Enero de 2020

Por mi coco pasa un tren, y hace tiempo que perdio la vía...

Evaristo Páramos

Agradecimientos

A todas las personas que ayudan a crear conciencia.

Índice general

I	Memoria	1
1.	Introducción	3
1.1.	Objeto	6
1.2.	Estructura de la memoria	6
2.	Marco Teórico	9
2.1.	Introducción	9
2.1.1.	Tecnología hiperspectral	9
2.1.2.	Teledetección de alta resolución UAV	10
2.2.	Fundamentos de clasificación de imágenes de teledetección	12
2.2.1.	Evaluación de los resultados de la clasificación	14
2.3.	Índices de Vegetación	16
2.3.1.	Índices de Vegetación	18
3.	Generación de cartografía del P.N. del Teide	29
3.1.	Metodología de clasificación empleada	29
3.2.	Preprocesado y correcciones de los datos dron	34
3.3.	Selección de datos de entrenamiento y evaluación	38
3.4.	Cálculo de índices de vegetación	42
3.5.	Clasificación de la imagen hiperspectral	50
3.5.1.	Clasificación empleando las bandas hiperspectrales	51
3.5.2.	Clasificación empleando árboles de decisión basados en VIs	56
3.5.3.	Clasificación empleando imagen compuesta por VIs	66
3.6.	Análisis de los resultados	69

4. Análisis del estado fenológico de la retama	81
4.1. Introducción	81
4.2. Metodología y Resultados	81
5. Conclusión General	89
5.1. Revisión de los objetivos	89
5.2. Análisis de los resultados	90
5.3. Líneas futuras	92
 II Pliego de Condiciones	 97
 III Presupuesto	 101
 Appendices	 110
 Appendices	 111

Índice de figuras

1.1. Parque Nacional del Teide.	5
2.1. Matriz de confusión genérica.	14
2.2. Clasificación de los Índices de Vegetación empleados en este Trabajo. .	20
3.1. Metodología de clasificación empleada.	30
3.2. Etapa de preprocesado de la imagen hiperespectral de dron.	34
3.3. Imagen obtenida por el dron y el recorte seleccionado para este Trabajo.	37
3.4. Imagen preprocesada y características principales.	37
3.5. Clases que compondrán los distintos conjuntos de datos de entrenamiento.	38
3.6. Firmas espectrales de cada conjunto de datos de entrenamiento.	40
3.7. Diagrama de aplicación de la herramienta <i>Vegetation Index Calculator</i> de ENVI.	43
3.8. Diagrama de aplicación de la herramienta <i>Band Math</i> de ENVI.	43
3.9. Ejemplo de resultado del cálculo del índice ARVI con BM y VIC.	44
3.10. Ejemplos de mapas obtenidos tras el cálculo de Índices de Vegetación (VIs).	45
3.11. Procedimiento de obtención de <i>boxplots</i>	46
3.12. <i>boxplots</i> de índices evaluados con <i>ROI2</i>	47
3.13. Firma espectral para crear YNDVI.	48
3.14. Mapa de valores de YNDVI.	49
3.15. <i>Boxplots</i> de YNDVI con todos los grupos de entrenamiento.	49
3.16. Aplicación de algoritmos de clasificación sobre imagen hiperespectral. .	51
3.17. Proceso de aplicación de SVM sobre imagen hiperespectral.	52
3.18. Mapas clasificados con MAHA, SVM y MAXL.	55
3.19. Árbol de decisión genérico.	57

3.20. <i>Boxplots</i> de diferentes clases para un VI.	58
3.21. Histogramas de diferentes clases para un VI.	59
3.22. <i>boxplots</i> e histogramas para umbralizar árbol de decisión usando ROI_2.	62
3.23. Definición de nodos del árbol de decisión.	63
3.24. Mapa clasificado de vegetación y de superficies no vegetales.	63
3.25. Árbol de decisión generado con ROI_2.	63
3.26. Mapa clasificado con árbol de decisión umbralizado con ROI_2.	64
3.27. Metodología de clasificación con Índices de Vegetación y clasificadores.	66
3.28. Composición RGB a partir de las bandas hiperespectrales y de los índices ARVI, YNDVI y PRI.	67
3.29. Mapas clasificados a partir de imagen de VIs.	68
3.30. Procedimiento llevado a cabo para la obtención de estadísticas de un clasificador genérico.	71
3.31. Imágenes de mapas clasificados con MD y SAM.	75
3.32. Imágenes de mapas clasificados con SID y relación de errores entre las clases <i>retama</i> y <i>rosalillo</i>	76
3.33. Imágenes resultante de la clasificación a través de árbol de decisión con ROI_2.	78
3.34. Mapa clasificado con SVM y ROI_2 con (derecha) y sin (izquierda) filtro de mayorías 5x5	80
4.1. Retamas y conejos.	82
4.2. Metodología para generar información de valor para el análisis de la retama.	83
4.3. Resultados obtenidos del estado fenológico de las retamas con NDVI.	86
4.4. Comparativa visual de los VI calculados para la retama.	87
1. Extracción de los datos generados por ENVI.	114
2. Cálculo del maximo, minimo, media, mediana y stdv	114
3. Representación de las medidas obtenidas.	114
4. Resultados obtenidos con NDVI.	116
5. Resultados obtenidos con RENDVI.	117
6. Resultados obtenidos con MRENDVI.	118

ÍNDICE DE FIGURAS

7.	Resultados obtenidos con VREI1.	119
8.	Resultados obtenidos con SIPI.	120
9.	Resultados obtenidos con PRI.	121
10.	Resultados obtenidos con CR1.	122
11.	Resultados obtenidos con CR2.	123
12.	Resultados obtenidos con AR1.	124
13.	Resultados obtenidos con AR2.	125
14.	Resultados obtenidos con PSRI.	126
15.	SVM y MAXL.	128
16.	MAHA y DT.	129
17.	SVM con imagen de VIs.	130

Índice de tablas

2.1. Características principales del sensor Pika L.	12
3.1. Número de píxeles de cada ROI y cada clase.	39
3.2. Matriz de separabilidad (TD) para cada par de clases.	41
3.3. Resultados de clasificación promediados entre los 5 grupos de entrena- miento y evaluación.	54
3.4. Umbrales para árbol de decisión con <i>ROI_2</i>	61
3.5. Resultados de <i>Ov. Accuracy</i> y <i>Kappa Coeff.</i> para árbol de decisión con <i>ROI_1</i>	65
3.6. <i>Ov. Accuracy</i> y <i>Kappa Coeff.</i> para árbol de decisión con <i>ROI_2</i>	65
3.7. Resultados de precisión del mapa clasificado de la imagen ARVI + YND- VI + PRI.	69
3.8. Resultados finales de la metodología de clasificación (<i>Ov.Accuracy</i> y <i>Kappa Coef</i>) para cada ROI de entrenamiento.	72
3.9. Comparación de resultados <i>Ov.Accuracy</i> y <i>Kappa Coef.</i> obtenidos de clasificar la imagen hiperespectral y la imagen compuesta por VIs.	74
3.10. Resultados finales de los algoritmos de clasificación descartados: <i>Ov.Accuracy</i> y <i>Kappa Coef.</i>	76
3.11. Comparativa de las matrices de confusión para un mapa clasificado con SVM y para el mismo mapa posprocesado con un filtro de mayorías con un kernel 5x5.	78
5.1. Requisitos Hardware.	99
5.2. Requisitos Software.	99
5.3. Factores de corrección para el número de horas empleadas.	104
5.4. Precios y costes de amortización del hardware.	106

5.5. Precios y costes de amortización del software.	106
5.6. Precios y costes de la ejecución del trabajo más las amortizaciones y el acceso a Internet.	107
5.7. Coste final de redacción del trabajo.	107
5.8. Tabla de coeficientes para el cálculo del visado.	108
5.9. Calculo total de presupuesto base para el cálculo del visado.	108
5.10. Presupuesto total sin impuestos.	109
5.11. Presupuesto total.	110

Parte I

Memoria

Capítulo 1

Introducción

Las especies vegetales cubren gran parte de la superficie terrestre. Son parte esencial para el desarrollo saludable de los ecosistemas que habitan. En general, en los últimos años se ha producido una fuerte degradación del estado de la mayor parte de estos ecosistemas debida, principalmente, al efecto antropogénico al que se han visto sometidos. Incendios forestales, el efecto invernadero y la consiguiente subida de la temperatura de gran parte de los ecosistemas naturales que componen el planeta, así como modificaciones constantes en los habitats naturales han impedido, desde hace mucho tiempo, el desarrollo sostenible de gran parte de la vegetación del planeta. No obstante, de forma paralela a esta degradación, el ser humano ha tenido la preocupación constante de aplicar herramientas, inicialmente desarrolladas con un propósito diferente, para la monitorización y estudio del medio ambiente. Aunque actualmente la aplicación de técnicas de teledetección con carácter medioambiental está muy extendida en el mundo civil, el origen de la tecnología de teledetección puede referirse al ámbito militar.

La Primera Guerra Mundial supuso la aparición de la primera cámara aérea (J.T.C. Moore-Brabazon) y de las primeras técnicas de procesamiento fotográfico [1]. La óptica de las cámaras de reconocimiento, la evolución del radar y la consecuente mejora de los sistemas de comunicaciones tuvieron lugar durante la Segunda Guerra Mundial. Una vez más, fue el conflicto conocido como “Guerra Fría”, el contexto que originó el desarrollo de sensores ópticos para operaciones satelitales y de nuevas técnicas de tratamiento de datos. Poco después comenzó un proceso de liberalización para uso civil de la tecnología de teledetección que supuso el desarrollo de aplicaciones de exploración aérea y espacial para el estudio y seguimiento de los recursos naturales a través de

imágenes [2].

En este contexto nació el término de teledetección ambiental, albergando en su definición a todas aquellas aplicaciones basadas en capturar imágenes remotamente y estudiar su contenido para detectar y monitorizar el estado de los ecosistemas de la superficie. En el ámbito espacial de observación de la Tierra, el satélite TIROS-I (1960) fue el primero en llevar a cabo misiones de observación meteorológica y, años más tarde, plataformas como Landsat o NOAA (National Oceanic and Atmospheric Administration), impulsaron un crecimiento exponencial del uso de técnicas de teledetección espacial para el seguimiento y control de recursos naturales empleando sensores multispectrales. A comienzos de la década de los 90, el desarrollo de la espectrometría dio lugar a la aparición de los sensores hiperespectrales, que incrementando enormemente los volúmenes de información recogidos en una imagen, impusieron la necesidad de un potente desarrollo en muchos campos de la teledetección. Por otro lado, el último avance tecnológico que se sumó para mejorar y aumentar el número de aplicaciones de la teledetección ambiental fue la aparición del dron (Unmanned Aerial Vehicle, UAV). Como se verá más adelante, las imágenes hiperespectrales de teledetección tomadas desde un dron, permiten analizar parámetros relativos a una superficie vegetal con mayor detalle que las obtenidas desde satélites.

El estudio del comportamiento espectral de la reflectancia para cada longitud de onda concentra el foco de investigación en la detección del estado de una planta mediante técnicas de teledetección. La reflectancia de las plantas es un parámetro espectral que depende principalmente de la composición del material de la hoja y de sus características físicas y químicas. No obstante, la reflectancia de gran parte de las especies vegetales comparte ciertos patrones generales comunes a gran parte de las especies vegetales: baja reflectividad en el espectro visible, muy alta en el infrarrojo cercano y con presencia de algunos máximos relativos en el SWIR (Short-Wave Infrared) [3]. Para extraer información del estado de la planta a partir de esta reflectancia se emplean Índices de Vegetación (IV). Su objetivo es detectar parámetros relevantes a partir de operaciones algebraicas entre valores de reflectancia en distintas bandas. Existen una serie de VIs y técnicas de clasificación diseñados específicamente para ser aplicados a datos de carácter hiperespectral. Todo este desarrollo hace posible la detección de diferentes estados relativos a propiedades bioquímicas, de estrés de la planta o su es-

estructura, y por tanto, la separación de diferentes clases vegetales en función de si presentan características saludables o no [3].

Concretamente, este Trabajo trata de explotar las características hiperespectrales y de alta resolución espacial (10 cm) de una imagen correspondiente a una zona de una importante concentración de especies vegetales específica del Parque Nacional del Teide (PNT), Tenerife (Figura 1.1). Este espacio fue declarado Parque Nacional en 1954 y Patrimonio de la Humanidad en 2007 por la UNESCO. Contiene un gran número de especies endémicas y la biodiversidad que alberga le otorga una alta importancia natural. Según los informes de las personas encargadas de salvaguardar el bienestar de las especies del Parque, el estado de la vegetación ha empeorado en las últimas décadas. Esta vegetación, por las características que le confieren sus condiciones de alta montaña, es muy sensible a las posibles modificaciones que sufra su entorno. En este contexto, la introducción de especies externas con la capacidad de cambiar la dinámica natural de las especies propias del ecosistema, unida al cambio de temperatura global, se posicionan como primera causa de la degradación de la vegetación del Parque. Concretamente, la población de una especie emblemática ha disminuido drásticamente, la retama del Teide (*Spartocytisus supranubius*)[4]. Ante esta situación, es de relevancia generar cartografía de la zona para estudiar la variación de la cobertura vegetal, a través de una metodología de clasificación de imágenes de alta resolución, y de detectar e identificar las causas de la degradación mencionada anteriormente haciendo uso de Índices de Vegetación VIs.



Figura 1.1: Parque Nacional del Teide.

La herramienta con la que se llevará acabo el análisis de la imagen hiperespectral es ENVI. Se trata de un *software* de análisis y visualización de imágenes que incorpora los módulos necesarios para el completo procesado de la imagen[5]. Los objetivos de este Trabajo se definen a continuación.

1.1. Objeto

Como objeto principal, este trabajo trata de aportar información detallada de interés que permita la generación de cartografía de especies vegetales del PNT. Adicionalmente, se tratará de aportar información para caracterizar el estado de salud de una especie endémica cuyo estado se ha degradado significativamente en los últimos años, la retama del Teide. Los objetivos específicos son los siguientes:

- Conocer las principales características de la tecnología hiperespectral aplicada en teledetección y las técnicas de clasificación aplicadas a imágenes hiperespectrales de entornos vegetales.
- Estudiar los Índices de Vegetación publicados y evaluar su comportamiento al aplicarlos sobre una imagen hiperespectral de alta resolución espacial.
- Generar cartografía de una selección de especies vegetales del Parque Nacional del Teide mediante una metodología de clasificación de imágenes hiperespectrales.
- Analizar el estado de salud de la retama a través de la aplicación de Índices de Vegetación.

1.2. Estructura de la memoria

La estructura que sigue este documento para presentar el trabajo de clasificación y análisis realizado sobre la imagen hiperespectral del PNT consta de las diferentes partes descritas a continuación:

- Los conceptos teóricos necesarios para un correcto entendimiento del trabajo realizado se presentan en el Capítulo 2. Primero, se definen los principios básicos de la tecnología hiperpespectral y las principales aplicaciones de la teledetección basada en UAVs. Seguidamente se presentan los fundamentos de los algoritmos de

clasificación empleados y, para terminar, se definen las principales características espectrales de la vegetación y los VIs empleados.

- Todo el trabajo de clasificación realizado se desarrolla en el Capítulo 3. De forma secuencial, se describen las operaciones de preprocesado que fueron aplicadas sobre la imagen y la obtención de los diferentes VIs. Así como el proceso de creación, validación de los conjuntos de datos de entrenamiento generados para la clasificación. Posteriormente se detallan los procesos de clasificación llevados a cabo y para concluir, se presentan los resultados obtenidos.
- Con los resultados de clasificación obtenidos y la información extraída en el desarrollo para su cálculo, se presenta la metodología empleada para focalizar el análisis sobre la retama. Se presenta definir un procedimiento que permita generar resultados de valor añadido para que, en este caso, expertos medioambientales puedan evaluar el estado de esta especie de forma más precisa.

Capítulo 2

Marco Teórico

2.1. Introducción

Con el fin de definir las bases teóricas de todo el procedimiento realizado en este Trabajo, se describen brevemente los conceptos que permitirán un mejor entendimiento del mismo. Sobre ellos se asienta todo el desarrollo realizado para la obtención de los resultados finales.

2.1.1. Tecnología hiperespectral

El persistente avance tecnológico en el campo de la electrónica, la óptica y la computación supone, como en multitud de campos, un desarrollo constante de los sensores de captación de imágenes, la espectroscopía y la capacidad computacional empleada para el procesamiento de imágenes. En este contexto, la tecnología hiperespectral estableció un nuevo paradigma en la captura y el tratamiento de imágenes. El principio de esta tecnología se basa, fundamentalmente, en detectar la radiación reflejada en un gran número de intervalos prácticamente contiguos a lo largo del espectro electromagnético. En esta afirmación se haya la principal diferencia con la tecnología multispectral: mientras los sensores multispectrales son capaces de detectar la radiación reflejada en unos pocos intervalos(bandas) espectrales, los análogos con tecnología hiperespectral permiten hacerlo en decenas o cientos de estas bandas, lo cual provee una firma espectral o curva de reflectancia detallada del comportamiento espectral de los elementos de la superficie terrestre. Además, en el ámbito vegetal una imagen hiperespectral dispone de información suficiente para estimar algunas propiedades biofísicas y bioquímicas de la planta,

así como caracterizar diferentes factores antropogénicos y fenológicos influyentes sobre ella [6].

Por tanto, de la misma forma que en el caso multiespectral, en el que una imagen se puede entender como una superposición de cada una de las bandas correspondientes a la reflectividad de diferentes rangos espectrales, una imagen hiperespectral no es más que una superposición de imágenes correspondientes a cada longitud de onda. Otra de las características más importantes de las imágenes hiperespectrales de teledetección es su capacidad de representar bandas más allá del espectro visible. Es muy común que los sensores de alta resolución capturen la reflectividad en longitudes de onda pertenecientes al espectro infrarrojo y ultravioleta (350 nm - 1500 nm).

Típicamente, los sensores hiperespectrales son capaces de contener más de 100 bandas, separadas por unos pocos nanómetros, en las que se mide la energía reflejada en un rango espectral que abarca las regiones ultravioleta, visible e infrarroja (350 nm - 1500 nm). Todas ellas superpuestas de forma ordenada componen lo que se conoce como un cubo de datos hiperespectrales (HDC), o hipercubo, y como tal, se puede expresar como un conjunto de datos ordenados en tres dimensiones (x, y, λ) . Las dos primeras (x e y) se corresponden con las dimensiones espaciales y λ con una dimensión espectral, tan amplia como el rango espectral capturado por el sensor. Esta última dimensión es la que hace posible el análisis vegetal de forma precisa, estudiando el comportamiento de la reflectancia en cada longitud de onda. Así, con una imagen hiperespectral, se podrán estimar algunos parámetros relacionados con el estado fenológicos en los que se puede encontrar una planta [7].

2.1.2. Teledetección de alta resolución UAV

El término teledetección engloba multitud de herramientas y funcionalidades en diversos campos de aplicación, que no ha dejado de ampliarse con el paso del tiempo. A pesar de que los mayores avances en este contexto fueron provocados por la incorporación de sensores ópticos, en principio multiespectrales, en plataformas espaciales, las limitaciones a efectos de resolución que ello conlleva impulsaron enormemente el desarrollo de los microsensores hiperespectrales y, especialmente, de unas plataformas que operan a menor altitud y cuyas dimensiones posibilitaron multitud de nuevas aplicaciones, los drones (UAV). Particularmente, en las aplicaciones de monitorización y

estudio de espacios vegetales, naturales o agrícolas, la teledetección de alta resolución UAV posee características que solucionan algunas de las limitaciones más importantes de la teledetección satelital para este propósito, actuando de forma complementaria y con efectividad en multitud de aplicaciones validadas: agricultura de precisión [8, 9], monitorización medioambiental [10] y calidad vegetal urbana [11].

- Debido a la distancia a la que son capturados, los datos obtenidos por sensores incorporados en satélites deben ser calibrados de forma que se puedan reducir los efectos geométricos y atmosféricos que contribuyen negativamente en la calidad de la imagen capturada. La tecnología dron no permite omitir toda la cadena de preprocesado necesaria para adecuar la imagen, pero no requiere esta calibración, lo cual es una ventaja aunque existan multitud de técnicas que consiguen resolver en gran medida, estos efectos en aplicaciones satelitales.
- Un sensor hiperespectral instalado en un satélite proporcionará datos con gran resolución espectral y poca resolución espacial, por lo que el píxel contendrá grandes áreas de superficie real, dificultando los posibles análisis de forma precisa en contextos de vegetación muy junta o entremezclada. En cambio, los sensores hiperespectrales implementados en UAVs disponen de gran resolución espectral, y también, espacial, proporcionando píxeles con información de tamaño muy reducido (del orden de pocos centímetros: 1-20cm) y radiométricamente muy precisos.

Dejando a un lado la tecnología y sensores empleados en plataformas espaciales, antes de que se comenzaran a emplear drones de tamaño y *payload* reducidos, los sensores implementados con tecnología hiperespectral se utilizaban, dadas sus dimensiones, en plataformas aéreas tripuladas [11]. A pesar de que aún la regulación adjunta a la tecnología dron limita bastante las posibilidades y zonas de vuelo, su desarrollo le aporta a las aplicaciones científicas y de investigación basadas en teledetección de ultra alta resolución una mayor flexibilidad de operación, lo cual ha incrementado exponencialmente su uso en los últimos años. Actualmente, existe una amplia gama de UAVs capaces de portar sistemas de captación de imágenes hiperespectrales, con todo el hardware necesario para su operación (generalmente, el sensor, un dispositivo que registre los datos obtenidos y un sistema de baterías enmarcado en un frame de montaje), con un rango de pesos *payload* de 3 a 10kg ([12]).

La imagen con la que se ha llevado a cabo este Trabajo ha sido tomada por el sensor Pika-L, de *Resonon* [13] y sus características principales se adjuntan en la Tabla 2.1. El dron empleado es el DJI Matrice 600 [14].

Tabla 2.1: Características principales del sensor Pika L.

Característica	Valor
Tipo	pushbroom
Rango espectral (nm)	400 – 1000
Resolución espectral (nm)	2,1
Canales espectrales	281
Canales espaciales	900
Max. Frame Rate (fps)	249
Profundidad de bits	12
Peso (kg)	0,6
Dimensiones (cm)	10x12,5x5,3

Como se aprecia en la Tabla 2.1, este sensor no captura longitudes de onda del rango ultravioleta. Si bien esto no impide que los datos adquiridos sean de valor para este estudio, se pierde la posibilidad de estimar parámetros que la vegetación manifiesta en este rango espectral, como el contenido de humedad o la concentración de pigmentos que pueden ser útiles en la detección de vegetación senescente. En la Sección 2.3 de este Capítulo se definen las principales características vegetales asociadas a cada zona del espectro capturado.

2.2. Fundamentos de clasificación de imágenes de teledetección

Los procedimientos a través de los cuales se ha realizado la separación de clases de la imagen hiperspectral siguen una metodología de clasificación supervisada [15]. Los datos de entrenamiento que se han empleado se han creado manualmente seleccionando regiones de píxeles directamente sobre la imagen (el proceso está detallado en la Sección 3.3 del Capítulo 3). A continuación se presentan los algoritmos de clasificación que se han utilizado.

- El clasificador más avanzado de todos los que se han aplicado es el *Support Vector Machine* (SVM) [16]. Clasifica a partir de una superficie de decisión que maximiza la distancia entre dos clases, llamada hiperplano, sobre un espacio de

características. En este trabajo se utilizará un kernel gaussiano para la ejecución de este algoritmo, ya que, generalmente, es el que proporciona mejores resultados. No obstante es posible emplear kernels de distinta naturaleza en función de la expresión matemática que empleen (no lineal, polinómico, etc.).

- *Maximum Likelihood* [17] sigue un principio de separación basado en la distribución de probabilidad de las diferentes clases. Esto es, para una muestra dada, este algoritmo calcula la probabilidad de que pertenezca a cada una de las clases, asignándola finalmente a la que obtenga un valor más alto. Como parámetro de entrada se puede establecer un umbral para descartar ciertos píxeles que no alcancen una probabilidad mínima.
- El algoritmo clasificador *Mahalanobis Distance* [18] lleva a cabo una operación similar a la de *Maximum Likelihood*, con la diferencia de que en este caso se suponen todas las covarianzas iguales, lo cual lo convierte en un algoritmo más rápido.
- La técnica *Minimum Distance* [19] sigue uno de los procesos más sencillos. Básicamente, calcula la distancia euclidiana desde un píxel desconocido hasta el vector medio de cada clase obtenido durante la etapa de entrenamiento, clasificándolo finalmente en la clase más cercana. Se puede establecer un umbral de distancia o una desviación estándar como parámetros de entrada que modifiquen los criterios de clasificación.
- *Spectral Angle Mapper* [19] es un algoritmo de clasificación espectral basado en hacer buscar la máxima coincidencia entre los píxeles a clasificar y los valores de referencia espectralmente. Para determinar la similitud entre dos clases calcula el ángulo entre los espectros involucrados. La clase de referencia con la que se tenga un menor ángulo será a la que se asigne el píxel evaluado.
- El algoritmo *Spectral Information Divergence* [19] está basado en obtener una medida de divergencia entre el píxel evaluado y las clases de referencia. Cuanto más pequeña es la divergencia, mayor será la similitud.

2.2.1. Evaluación de los resultados de la clasificación

La evaluación de los mapas clasificados se ha realizado haciendo uso de las matrices de confusión con cada uno de los conjuntos de entrenamiento [1]. Estas matrices no sólo aportan información acerca de la precisión global obtenida de la clasificación, también ofrecen determinados indicadores que permiten estudiar cómo y en qué medida el clasificador ha confundido las muestras mal clasificadas. Para explicar la configuración y la forma de interpretar una matriz de confusión se va a utilizar la matriz de la Figura 2.1, cuyos valores son supuestos para este ejemplo. El total de muestras (píxeles) clasificadas (filas) son asignadas a las clases que se suponen verídicas (predicciones o valores reales). Así, se podrá evaluar de forma precisa como ha sido clasificada cada una de las clases. Según se lea la matriz en filas o en columnas, los errores y, por consiguiente, la precisión, pueden ser interpretados de desde dos perspectivas distintas, explicadas en el siguiente ejemplo:

		Valores reales				
		Clase A	Clase B	Clase C	Clase D	
Clasificación	Clase A	500	12	0	28	540
	Clase B	19	481	10	4	514
	Clase C	1	0	512	7	520
	Clase D	33	10	5	518	566
		553	503	527	557	
Número total de píxeles de cada clase real						

Figura 2.1: Matriz de confusión genérica.

- En este ejemplo, el clasificador ha asignado una muestra a la clase A, siendo esta realmente de la clase B. Así se interpretan los errores cometidos horizontalmente (filas) en la Figura 2.1. Por ejemplo, el clasificador con el que se ha obtenido la matriz genérica de la imagen ha considerado que 540 muestras pertenecen a la clase A, sin embargo, realmente sólo 500 han sido clasificadas correctamente. Así,

las 12 muestras de la clase B y las 28 muestras de la clase D serán errores cometidos por el clasificador, más comunmente conocidos como errores de comisión. Estos errores son un indicativo de cuánto se equivoca el clasificador discriminando muestras de las diferentes clases. Se calcula como el número de muestras totales mal clasificadas ($12 + 28$) entre el número total de muestras que el clasificador le ha asignado a esa clase (540). Con la parte restante de las muestras (500) es posible calcular un parámetro de precisión conocido como *User's Accuracy*, el cual da una idea de la fiabilidad del clasificador y se calcula como el número de muestras clasificadas correctamente en esa clase (500), entre el total de muestras que han sido asignadas a la misma. El nombre se debe a que el punto de vista desde el cual se interpreta este parámetro es el del usuario del mapa clasificado, que difiere del punto de vista del creador del mapa, como se verá a continuación.

- Una muestra de la clase B ha sido asignada por el clasificador a la clase D. Esta lectura se correspondería con el análisis vertical (columnas) de la matriz. Por ejemplo, en la imagen se puede comprobar como de las 503 muestras pertenecientes realmente a la clase B, sólo 481 han sido discriminadas correctamente por el clasificador y, 12 muestras clasificadas en la clase A y 10 muestras clasificadas en la clase D. Estos errores son conocidos como errores de omisión y se calculan como el número de muestras clasificadas en clases incorrectas ($10 + 12$) entre el número total de muestras de esa clase real (503). A estos errores va ligado un parámetro de precisión, conocido como *Producer Accuracy*. Esta precisión se evalúa desde el punto de vista del creador (productor) del mapa clasificado.
- Finalmente, los dos parámetros con los que se caracteriza la bondad del clasificador son *Overall Accuracy* y *Kappa Coefficient*. El primero de ellos se obtiene como la división del número total de muestras clasificadas correctamente entre el total de muestras del conjunto de datos de referencia, expresando el resultado en porcentaje. El coeficiente Kappa trata de caracterizar la influencia del azar sobre las muestras clasificados correctamente, por esta razón se entiende que es una medida más robusta que la precisión global [20]. Existen diferentes definiciones de este coeficiente, no obstante la empleada por ENVI para su cálculo es la

siguiente [5]:

$$k = \frac{N * (\sum_{i=0}^n e_i - \sum_{i=0}^n (C_i G_i))}{N^2 - \sum_{i=0}^n (C_i G_i)} \quad (2.1)$$

donde N es el numero de píxeles clasificados en comparación con los valores de referencia. e_i representa a los valores clasificados en la clase i , siendo de la clase i , o lo que es lo mismo, la diagonal principal de la matriz de confusión. C_i representa a los valores clasificados en la clase i y G_i a los valores que de verdad pertenecen a la clase i . Su resultado está acotado entre 1, correspondiente con concordancia perfecta y 0, con una concordancia nula.

Una vez vistos los principales parámetros que se pueden extraer de las matrices de confusión, se puede entender en mejor medida el comportamiento con el cual un clasificador ha separado las distintas clases para obtener el mapa resultante. La matriz de confusión que aporta ENVI muestra, de forma desglosada, los los errores de omisión y comisión, y por tanto, la precisión de usuario y de productor. Con ellos, se podrá caracterizar el error cometido en cada clase y de forma separada, la precisión con la que ha clasificado desde ambos puntos de vista. De esta manera, además, se podrá asegurar la validación del proceso de clasificación de forma más robusta, no sólo indicando la precisión obtenida, sino entendiendo, en la medida de lo posible, la razón por la cual han sido cometidos los errores.

Se debe tener en cuenta que si se pretende utilizar el mejor resultado de clasificación para, por ejemplo, generar una máscara que permita extraer píxeles (muestras) de una clase concreta, se debe estudiar con detalle la matriz de confusión y, de forma particular, cómo se han clasificados los píxeles que se pretendar emplear como máscara. El mapa con el que se generará la máscara más precisa no tiene por qué ser el que mejor resultados presente de precisión global y coeficiente Kappa. Este procedimiento se ha llevado a cabo en este Trabajo para obtener la máscara empleada para extraer la retama (Capítulo 4).

2.3. Índices de Vegetación

El agua, el suelo, la vegetación, las zonas urbanas y cualquier superficie que se pretenda analizar a través de la radiación electromagnética que refleja de forma natural está caracterizada por su firma espectral. Independientemente de los factores relacio-

nados con el estado de la superficie o de las condiciones de iluminación en el momento de la captura de la imagen, cada tipo de superficie muestra en su firma espectral un comportamiento característico. Así, de forma general, se puede estimar en qué regiones espectrales se concentra la información de interés para un determinado propósito según el tipo de superficie. O se pueden establecer patrones de diferenciación entre superficies (clases) basados en la reflectancia en una región espectral determinada.

Por ejemplo, el agua refleja solamente la parte de radiación correspondiente al visible, la reflexión del suelo desnudo (de forma general, salvando los distintos tipos de superficie de suelo) aumenta conforme se avanza desde la región visible a la infrarroja. Así, si se pretende separar las clases suelo y agua de una imagen determinada se podría comparar el contenido de información que presenta cada píxel en la región infrarroja(citePu2011. De la misma manera se realiza la separación entre distintos tipos de superficies. La firma espectral de la vegetación verde es muy característica. Para el proceso de fotosíntesis, las plantas absorben gran parte de la radiación del rango visible, especialmente en las longitudes de onda del rojo, sin embargo reflejan en gran medida la radiación del espectro infrarrojo cercano (NIR), la cual no emplean para ninguna de sus funciones vitales y reflejarla les permite regular su temperatura, y así el contenido de humedad y el estrés.

Por el contexto en el que se encuentra enmarcado este Trabajo, a continuación se expondrán algunos conceptos relativos a las características y el comportamiento espectrales de la radiación reflejada por la vegetación. Serán de gran valor para comprender mejor la definición de los Índices de Vegetación, una herramienta muy extendida que permite estimar diferentes parámetros de la vegetación empleando para ello operaciones matemáticas entre diferentes bandas espectrales.

Además de la ya comentada absorción de las longitudes de onda del visible, las propiedades de la reflectancia de una especie vegetal dependen de muchos otros factores: el estado físico y químico de la planta, la estructura foliar de la hoja, el ángulo de incidencia de la radiación solar, etc. La curva de reflectancia obtenida de una especie vegetal común se caracteriza por [7]:

- La reflectancia en el rango espectral de las longitudes de onda azul a roja es muy baja. La clorofila absorbe la luz de este rango (aprox. 450 nm a 670 nm) y refleja gran parte en el rango infrarrojo. En esta parte reflejada se concentra la

mayor parte de la información potencialmente útil para caracterizar el estado de la planta.

- El aspecto de la curva de reflectancia de la vegetación sana no son idénticas, pero sí existe un denominador común entre todas ellas. En el intervalo correspondiente a la transición de las longitudes de onda del rojo a las del infrarrojo cercano se concentra gran parte de la información del estado de la estructura celular de la planta. Lo cual, además de contener la mayor parte de información de interés relativa a la planta, permite emplear estas bandas para diferenciar especies.
- La radiación ultravioleta reflejada apenas proporciona información útil para la estimación de parámetros de la planta. No obstante, normalmente a más altura, más radiación UV, y en estas condiciones se pueden obtener parámetros relativos al contenido de agua y a la concentración de carotenoides en las longitudes de onda cercanas por el borde inferior a las del azul (450 nm).

Conocidas las zonas espectrales que contienen la información, se pueden establecer operaciones matemáticas, a menudo normalizadas, entre diferentes bandas que permitan la obtención de un parámetro determinado. Así, existe una estrategia que le da nombre a la funcionalidad anterior, los Índices de Vegetación, VI.

2.3.1. Índices de Vegetación

Los VI aplicados en teledetección son operaciones basadas en evaluar cuantitativamente y cualitativamente parámetros característicos de un entorno vegetal utilizando información espectral [3]: vigor de la cubierta analizada, la dinámica de crecimiento de la misma, etc. La operación matemática que conforma un índice determinado combina las medidas de reflectancia de diferentes regiones espectrales (índices multiespectral) o de diferentes longitudes de onda específicas (índices hiperespectrales). Muchos factores influyen en el resultado final de la imagen, como el propio sensor que la captura, la plataforma que lo porta y las resoluciones empleadas, entre otros. Por esta razón, la tarea de elegir qué bandas se emplean para calcular un índice determinado tiene una gran influencia sobre el resultado final del mismo. Además, si bien la firma espectral de las especies vegetales sigue un patrón común, no existen dos firmas idénticas, ni siquiera

de la misma especie. Así, es muy común encontrar varias definiciones del mismo índice que emplean para su cálculo la reflectancia de bandas diferentes [21].

Actualmente hay una gran cantidad de VI, y por ello se suelen agrupar en diferentes categorías en función del espectro que utilizan para su cálculo o del propósito para el cual han sido diseñados. Existen multitud de estos propósitos y de naturaleza muy distinta, pero la mayoría de ellos emplea la reflectancia de bandas correspondientes al final del espectro visible (RED) y el principio del no visible (NIR). En la Figura 2.2 se muestran los índices de vegetación empleados en este Trabajo, están divididos en cuatro grandes grupos y las características de cada uno [5, 3] se describen a continuación:

■ Índices de Banda Ancha (*Broadband Greenness VI*)

Los índices de banda de ancha tienen como principal misión medir de forma general la cantidad y el vigor de la vegetación. Son los índices más simples de todos, se basan en combinar los picos de reflectancia de las bandas del NIR y RED para tratar de medir la calidad del material fotosintético de la vegetación analizada. Se emplean estas bandas porque es en ellas donde se manifiestan con mayor influencia cambios en estructura vegetal, la acumulación de follaje y la concentración de clorofila. Los VIs de este tipo aplicados sobre la imagen hiperespectral son los siguientes:

● Normalized Difference Vegetation Index (**NDVI**)

Es el índice más común y extendido. Su funcionalidad es obtener una medida de verdor de la cubierta vegetal analizada. Para su cálculo se deben emplear las regiones de mayor absorción y reflectancia de clorofila, y como ya se ha comentado, éstas varían para cada especie vegetal. Es por ello que no existen bandas concretas que den resultados óptimos de este índice de forma general.

$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}} \quad (2.2)$$

Es un índice normalizado (-1 a 1), en el que se toma como vegetación vigorosa (verde) toda aquella situada en el rango $0,2 - 0,8$. En condiciones de alta densidad vegetal o en las que la imagen se vea afectada por efectos atmosféricos tiende a saturarse.

● Simple Ratio Index (**SRI**)




Figura 2.2: Clasificación de los Índices de Vegetación empleados en este Trabajo.

Surgió como una modificación de NDVI para entornos de alta densidad vegetal. Se basa en dividir la región de mayor reflectancia del espectro NIR entre su análoga del RED.

$$SRI = \frac{NIR}{Red} \quad (2.3)$$

Se ha demostrado que los valores de SRI aumentan conforme se incrementa la vigorosidad representada en los píxeles analizados. No es un índice normalizado y, generalmente, en torno a 30 se sitúan los valores de SRI más

altos.

- Enhanced Vegetation Index (**EVI**)

Tratando de solventar las deficiencias de NDVI en entornos de alta densidad vegetal y en situaciones en las que los efectos atmosféricos y de suelo afecten de manera muy negativa al resultado, surgió EVI. En la expresión matemática se introducen, además de la reflectancia del azul, tres constantes: las multiplicativas (6 y 7,5) tiene la función de corregir efectos atmosféricos y la aditiva (1) representa un ajuste para resolver los efectos negativos de la reflectividad del suelo, según (1353691).

$$EVI = 2,5 * \frac{NIR - Red}{NIR + 6 * Red - 7,5 * Blue + 1} \quad (2.4)$$

Es un índice normalizado, y al igual que NDVI entiende como vegetación vigorosa aquella cuyos valores oscilen entre 0,2 y 0,8. Es importante preprocesar la imagen de forma que las fuentes de brillo, como el suelo o las nubes queden enmascaradas, sino el efecto de la reflectancia en la banda azul podría saturar el resultado de multitud de píxeles.

- **Índices de Banda Estrecha (*Narrowband Greenness VI*)**

Los índices de banda estrecha están diseñados para el mismo propósito que los de banda ancha. La diferencia con respecto a estos es que para el cálculo, se emplean medidas de reflectancia en el rango comúnmente conocido como *Red-Edge*. Estos índices son capaces de detectar cambios más pequeños en algún parámetro vegetal, siempre y cuando se seleccionen las bandas más apropiadas para el cálculo. Los índices de este tipo aplicados en este Trabajo son los siguientes:

- Atmospherically Resistant Vegetation Index (**ARVI**)

Este índice es una mejora del NDVI. Trata de corregir los factores atmosféricos a través de una variable que caracteriza el tipo de nube (aerosol) que se pretende eliminar y la reflectancia del azul para corregir efectos relacionados con la dispersión atmosférica. Es muy específico, es decir, sólo mejora a NDVI en situaciones en las que las condiciones atmosféricas impidan su

uso.

$$\text{ARVI} = \frac{\rho_{800} - (\rho_{680} - \gamma(\rho_{450} - \rho_{680}))}{\rho_{800} + (\rho_{680} - \gamma(\rho_{450} - \rho_{680}))} \quad (2.5)$$

El resultado del índice oscilará entre -1 y 1 caracterizando la vegetación más verde con los valores más altos.

- Red Edge Normalized Difference Vegetation Index (**RENDVI**)

Es una modificación de NDVI basada en utilizar para el cálculo las medidas de reflectancia correspondientes con longitudes de onda del *Red-Edge*. Es uno de los índices más utilizados en agricultura de precisión, puesto que estas bandas presentan una alta sensibilidad a pequeños cambios en parámetros relacionados con la senescencia o el estrés de la vegetación.

$$\text{RENDVI} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}} \quad (2.6)$$

El resultado del índice oscilará entre -1 y 1 y el rango de valores para la vegetación vigorosa es $0,2$ y $0,9$.

- Modified Red Edge Normalized Difference Vegetation Index (**MRENDVI**)

MRENDVI es una modificación del índice anterior que trata de corregir la reflexión especular de las hojas incluyendo en su expresión la una medida de reflectancia en torno a los 450 nm.

$$\text{MRENDVI} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2 * \rho_{445}} \quad (2.7)$$

El resultado del índice oscilará entre -1 y 1 y el rango de valores para la vegetación vigorosa es $0,2$ y $0,7$.

- Modified Red Edge Simple Ratio (**MRESR**)

Es la modificación en banda estrecha de SRI. Emplea la reflectancia de las longitudes de onda del *Red-Edge* y emplea la misma banda que MRENDVI para corregir los defectos producidos por la reflexión especular de las hojas.

$$\text{MRESR} = \frac{\rho_{750} - \rho_{445}}{\rho_{750} + \rho_{445}} \quad (2.8)$$

No es un índice normalizado, su rango de valores oscila entre 0 y 30 aprox.

y considera vegetación vigorosa toda aquella resultante en el rango entre 2 y 8.

- Vogelmann Red Edge Index 1 (**VREI1**)

Este índice fue diseñado para estimar de forma aproximada diferentes parámetros relacionados con el desarrollo fenológico de la vegetación analizada. Emplea medidas de reflectancia en longitudes de onda del NIR, con lo cual la profundidad de penetración que se contempla es mayor que en el resto de índices y además de su función principal, aporta información de valor para cuantificar la vegetación que está por debajo de la cubierta observada en la imagen.

$$\text{VREI1} = \frac{\rho_{740}}{\rho_{720}} \quad (2.9)$$

El rango de valores resultantes de este índice va de 0 a 20 y, generalmente, la vegetación en buen estado de vigorosidad toma valores entre 4 y 8.

- Vogelmann Red Edge Index 2 (**VREI2**)

VREI2 esta basado en el mismo principio que el índice anterior, empleando para el cálculo la reflectancia de más longitudes de onda.

$$\text{VREI2} = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{726}} \quad (2.10)$$

Los rangos de valores posibles y de vegetación vigorosa son los mismos que en el caso anterior.

- **Índices basados en caracterizar cualitativamente el proceso fotosintético (*Light Use Efficiency VI*)**

Este grupo de índices se basan en medir la eficiencia con la cual la vegetación utiliza la luz incidente para la fotosíntesis. Para ello, la mayoría de estos índices emplean medidas de reflectancia en las longitudes de onda de mayor absorción de la clorofila y los carotenoides. Además, el uso eficiente de la luz es un buen indicador para estimar la absorción de carbono de la planta, y por tanto, aporta información importante relativa al crecimiento de la misma.

- Photochemical Reflectance Index (**PRI**)

Como su propio nombre indica, este índice está diseñado para obtener información del proceso fotosintético de la planta. Más concretamente, trata de obtener información de pequeños cambios en los carotenoides de la vegetación viva. Estos pigmentos participan de fundamentalmente en la transferencia de energía que realiza una planta en el proceso de la fotosíntesis. Con lo cual, a través de este índice se puede estimar la eficiencia con la que una planta usa la radiación para su principal función natural. Para ello, se emplean la reflectancia de las longitudes de onda de mayor absorción de carotenoides.

$$\text{PRI} = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}} \quad (2.11)$$

El valor de este índice oscilará entre -1 y 1 , tomando como valores de vegetación en buenas condiciones todos aquellos dentro del rango $(-0,2, 0,2)$.

- Structure Insensitive Pigment Index (**SIPI**)

SIPI es una medida de reflectancia cuya composición trata de maximizar la sensibilidad a cambios en los carotenoides y la clorofila contenida en las hojas. Valores altos de este índice indican un alto nivel de estrés.

$$\text{SIPI} = \frac{\rho_{800} - \rho_{445}}{\rho_{800} + \rho_{680}} \quad (2.12)$$

Los resultados de este índice oscilarán entre 0 y 2 y los valores mayores a $0,8$ se corresponden a niveles del pigmento carotenoide suficientemente altos con los que la planta podría estar manifestando estrés.

- **Índices para estimar cualitativa y cuantitativamente los pigmentos principales que componen las hojas (*Leaf Pigments VI*)**

Estos índices proporcionan una medida relacionada con el estrés de los pigmentos que componen las hojas en un estado de sequedad o senescencia. Así, todos los índices pertenecientes a esta categoría emplean reflectancias de longitudes de onda de las regiones de mayor absorción de carotenoides y antocianinas. Los primeros tienen una relevancia importante en la transferencia de energía que requiere la planta para realizar la fotosíntesis. Por otra parte, las antocianinas son pigmentos contenidos, generalmente, en hojas primerizas o en estado de senescencia, cuya

función principal es actuar como protección ante la radiación ultravioleta. Los índices de este tipo empleados en este Trabajo son los siguientes:

- Anthocyanin Reflectance Index 1 (**ARI1**)

Un alto contenido de antocianinas suele estar relacionado con un debilitamiento de la vegetación que las contiene. Emplea para el cálculo longitudes de onda del espectro visible, que es donde se manifiestan, principalmente, los efectos producidos por el estrés en las plantas.

$$\text{ARI1} = \frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \quad (2.13)$$

Los valores más altos de este índice se corresponden con la vegetación más estresada.

- Anthocyanin Reflectance Index 2 (**ARI2**)

Es una modificación del anterior, pero su funcionalidad es la misma, detectar estrés en vegetación a través de contenido de antocianina en la planta. La modificación consiste en ponderar el resultado del índice anterior con la reflectancia de una banda del NIR.

$$\text{ARI2} = \rho_{800} * \left(\frac{1}{\rho_{550}} - \frac{1}{\rho_{700}} \right) \quad (2.14)$$

Igual que en el caso anterior, a mayor valor, mayor concentración de antocianinas y por tanto, mayor estrés de la hoja.

- Carotenoid Reflectance Index 1 (**CRI1**)

Como ya se ha comentado, los carotenoides trabajan en los procesos de absorción de luz en las plantas y, al igual que las antocianinas, actúan como protectores ante un exceso de luz incidente. Una planta débil concentrará en sus hojas un contenido de carotenoides mayor que una planta sana, lo cual se convierte en una sencilla forma de detectar vegetación estresada. Emplea para el cálculo reflectancias en longitudes de onda de mayor absorción de los carotenoides.

$$\text{CRI1} = \frac{1}{\rho_{510}} - \frac{1}{\rho_{550}} \quad (2.15)$$

Los valores de este índice no están acotados. Entre 0 y 15 se consideran

valores dentro de un rango admisible. Comúnmente, la vegetación en buen estado está situada entre 1 y 12.

- Carotenoid Reflectance Index 2 (**CRI2**)

El índice anterior emplea las reflectividades de las zonas espectrales de mayor absorción de carotenoide, de tal forma que en condiciones de alta concentración de estos pigmentos puede llegar a saturar. Para solucionar este problema fue creado este índice, que no es más que una modificación del anterior. Para evitar la saturación emplea la reflectancia en una zona de menor absorción.

$$\text{CRI2} = \frac{1}{\rho_{510}} - \frac{1}{\rho_{700}} \quad (2.16)$$

Los resultados de este índice oscilarán entre 0 y 15 y se considerará vegetación saludable toda aquella situada en el rango entre 1 y 11.

- **Índices indicadores de vegetación seca o senescente (Dry or Senescence Carbon)**

Estos índices proporcionan una estimación del contenido de carbono en estado seco de partículas estructurales de la planta, celulosa y lignina. Ambas tienen una importante relevancia en la construcción del tejido celular de la planta. Un alto contenido de moléculas de carbono en estado de sequedad implica que la vegetación se encuentra en estado de senescencia o sequedad extrema. Fundamentalmente, estos índices se emplean para buscar vegetación en estos estados. Además, como el carbono seco es una partícula altamente inflamable, propio de materiales muy leñosos, estos índices tienen una gran importancia para la prevención de incendios o la detección de zonas de alto riesgo. Sólo se ha empleado un VI de este tipo, es el siguiente:

- Plant Senescence Reflectance Index (**PSRI**)

Este índice se basa en encontrar altas concentraciones de carotenoides, detectando así vegetación estresada o en estado de senescencia. Los valores más altos de este índice indican un alto grado de estrés en la vegetación.

$$\text{PSRI} = \frac{\rho_{680} - \rho_{500}}{\rho_{750}} \quad (2.17)$$

El rango de valores resultantes está acotado entre -1 y 1 y se considera vegetación en bien estado aquella en el rango $(-0,1$ a $0,2)$.

Capítulo 3

Generación de cartografía del Parque Nacional del Teide

3.1. Metodología de clasificación empleada

El procedimiento empleado para obtener los resultados cartográficos relativos a la vegetación del PNT, basado en la aplicación de diferentes estrategias de clasificación de una imagen hiperespectral, se ha realizado de manera que su posterior análisis sea lo suficientemente robusto para validar la información final de manera precisa. Consiste en aplicar una metodología de clasificación supervisada sobre la imagen hiperespectral, haciendo uso de una selección de algoritmos clasificadores disponible en el *software* ENVI y del uso de Índices de Vegetación. Estos últimos, además de aportar información relevante del estado general de la vegetación, también pueden emplearse como herramienta para separar las clases de la imagen. Si los datos de clasificación son válidos, el propósito de esta metodología es aportar información útil para el estudio cartográfico del ecosistema representado en la imagen y caracterizar, a grandes rasgos, el estado de las especies vegetales. De forma resumida, los pasos a seguir para el desarrollo de esta metodología se representan en la Figura 3.1.

■ PREPROCESADO Y CORRECCIONES.

Si bien este Trabajo comienza con la imagen hiperespectral captada por el dron DJI Matrice 600, preprocesada y con todas las correcciones ya realizadas, es importante conocer cuáles han sido las operaciones llevadas a cabo en la etapa de preprocesado [22]. Además, fue necesario aplicar ciertas correcciones sobre la




Figura 3.1: Metodología de clasificación empleada.

imagen ya preprocesada, pues en su firma espectral aparecía un pico atípico en un rango espectral de aproximadamente 20 nm. Todo el procedimiento llevado a cabo se describe de forma detallada en la Sección 3.2.

■ DATOS DE ENTRENAMIENTO Y EVALUACIÓN (ROIs).

Para poder operar con la imagen es necesario disponer de los datos de entrenamiento con los cuales se posibilitará el desarrollo de la metodología. Estos datos han sido seleccionados de forma manual sobre la imagen atendiendo a criterios que, a priori, faciliten la clasificación. Para ello, se han creado diferentes conjuntos de datos de entrenamiento atendiendo a diferentes características (bordes de vegetación, zonas con distinta iluminación, tonalidades de las plantas, etc.). La importancia de esta etapa es muy alta, pues no disponer de datos correctamente seleccionados afecta directamente sobre cualquier operación aplicada sobre la

imagen. Por esta razón, se ha realizado un estudio detallado de los datos seleccionados, con el objetivo de validarlos para su uso posterior, a través de las firmas espectrales de las superficies que representan y la evaluación de la separabilidad entre las clases que los componen.

El proceso completo de selección y validación de los datos de entrenamiento empleado en esta metodología se describe detalladamente en la Sección 3.3.

Por otro lado, los mapas resultantes que se pretenden obtener con esta metodología requieren ser sometidos a una evaluación que determine la validación de cada proceso de clasificación, así como la precisión del mismo. Como se verá en el correspondiente análisis de resultados obtenidos (Sección 3.6), el estudio de estos resultados de clasificación se ha realizado haciendo uso de la Matriz de Confusión, consistente en evaluar cómo han sido clasificadas las diferentes clases de la imagen por el clasificador, con respecto a unos datos de referencia que se suponen verídicos. Para estos valores de referencia, con los que se obtendrán las matrices, también han sido utilizados los conjuntos de datos definidos en este apartado.

■ ÍNDICES DE VEGETACIÓN (VI).

Se han obtenido una serie de VIs y se han procesado los resultados obtenidos de manera que su análisis permita, por un lado, estimar parámetros relativos al estado de la planta y, por otro, ser aplicados en diferentes procesos de clasificación sobre la imagen hiperespectral. La importancia de estos índices radica en la naturaleza de esta imagen pues, con este trabajo, se pretende aportar información que permita explicar el estado de ciertas características y parámetros fenológicos que pueden estar afectando a la vegetación representada. El procedimiento llevado a cabo para el cálculo de los diferentes VIs y el procesamiento de los resultados obtenidos se detalla en la Sección 3.4.

■ CLASIFICACIÓN DE LA IMAGEN HIPERESPECTRAL.

Para obtener la cartografía del PNT se han evaluado tres metodologías que permitan clasificar la imagen disponible. Cada una de ellas se ha centrado en explotar diferentes herramientas disponibles en el *software* ENVI. Concretamente se han desarrollado tres procedimientos de clasificación. El primero ha consistido en hacer uso de los algoritmos de clasificación conocidos y todas las bandas

hiperespectrales disponibles, de manera que empleando los datos de entrenamiento generados anteriormente se podrá obtener un mapa clasificado con cada uno de ellos. Se pretende, además de generar las imágenes clasificadas, estudiar el comportamiento de estos algoritmos aplicados sobre una imagen hiperespectral de un entorno vegetal, de forma que sea posible recomendar aquellos que mejor resultado den para imágenes de características similares. Por otro lado, los VIs calculados previamente generan datos válidos para aplicar dos procesos de clasificación diferentes. Uno de ellos está basado en emplear otra imagen de entrada al clasificador, resultante de una combinación de distintos índices para ser clasificables por los distintos algoritmos de clasificación implementados en ENVI. El otro, consiste en implementar árboles de decisión, basados en los valores resultantes de los índices que permitan separar las distintas clases de la forma más precisa posible y dar como resultado una imagen clasificada. Se detallan los procedimientos llevados a cabo para cada una de las tres metodologías en las Secciones 3.5.1, 3.5.2 y 3.5.3.

■ RESULTADOS DE CLASIFICACIÓN.

Una vez han sido aplicadas las operaciones descritas en el punto anterior, se ha realizado un procedimiento de validación de cada una de ellas, en base a los resultados obtenidos haciendo uso de las matrices de confusión generadas con los distintos grupos de entrenamiento. Además, ha sido posible realizar una comparación que permita identificar qué metodología de clasificación de las aplicadas es más apta para este tipo de estudios. Una vez finalizado este proceso, se habrán obtenido una serie de imágenes clasificadas que conformarán un bloque de información cartográfica del ecosistema analizado. Todo este proceso es descrito con detalle en la Sección 3.6.

■ ANÁLISIS DE LA RETAMA.

Aprovechando los resultados que se han obtenido y procesado a través de la aplicación de los diferentes VI, ha sido posible realizar un estudio específico de una de las clases vegetales que aparecen en la imagen, la retama. Dado que la evaluación de las características vegetales no entra dentro del marco establecido por este trabajo, el procedimiento llevado a cabo se ha centrado en generar informa-

ción que sea fácilmente interpretable por expertos específicos del ámbito vegetal. Para ello, a través de los resultados de los VIs y de la clasificación de la imagen, se ha podido focalizar en el estudio específico de la retama. Como resultado, se presentan diferentes mapas con información relativa a su estado. Todo este procedimiento ha sido descrito en el Capítulo 4.

Debido a la gran cantidad de píxeles de la imagen y a la variabilidad de su contenido, la selección de los datos de entrenamiento tendrá una influencia muy importante sobre el resultado de la clasificación, del cuál dependerá la validez del proceso. Por esta razón, se han creado 5 conjuntos de datos que contengan píxeles distintos y representativos de las mismas clases. Todos los mapas generados en el desarrollo de este Trabajo son obtenidos haciendo uso de todos estos conjuntos. Así se dispondrá de material suficiente para estudiar el comportamiento del clasificador, aplicado para separar clases de imágenes similares. Algunas de las ventajas que aporta realizar la clasificación de esta forma son las siguientes.

- La posibilidad de promediar los resultados de clasificación y evaluación de índices obtenidos de cada conjunto, persiguiendo que el análisis final de los resultados sea más robusto ante errores de selección en los datos de entrenamiento. Además, será necesario para comprobar la validez de cada conjunto de estos datos.
- Mejorar el conocimiento acerca del comportamiento de los clasificadores y de la imagen, esto es, si se selecciona cada conjunto bajo unos criterios específicos (selección de bordes, zonas afectadas por sombras, etc), se dispondrá de resultados que permitan, por ejemplo, estimar qué zonas de la imagen generan más confusión en los clasificadores, facilitar la creación de máscaras que sean beneficiosas para la clasificación o dar una idea de los factores de corrección que sería recomendable aplicar.
- A partir de las firmas espectrales se podrá analizar la posibilidad de crear un índice de vegetación específico optimizando las bandas utilizadas y, a través de los análisis de separabilidad de cada conjunto de datos, se podrá estimar cuán separables son las clases entre sí de manera más fiable.

3.2. Preprocesado y correcciones de los datos dron

El elemento principal sobre el cual se aplicará todo el trabajo realizado es la imagen hiperespectral capturada y preprocesada. Por esta razón, aunque no han sido ejecutadas a cabo en este Trabajo, es importante conocer cuáles han sido las operaciones llevadas a cabo desde la obtención de la imagen hasta el momento en el que ha sido posible comenzar la metodología de clasificación y el cálculo de los diferentes VI.




Figura 3.2: Etapa de preprocesado de la imagen hiperespectral de dron.

En la Figura 3.2 se han representado las diferentes etapas por las que ha pasado la imagen. De forma más detallada, la secuencia llevada a cabo en este procedimiento se describe de la siguiente forma:

- **CAPTURA.** El sensor hiperespectral portado por el dron captura niveles de **irradiancia solar** durante el vuelo, el área de barrido del dron en la captura de la imagen es de aproximadamente 1 km, y diversos efectos atmosféricos afectan negativamente a la calidad de la información obtenida.
- **PREPROCESADO.** La imagen empleada se corresponde con un trozo de la zona norte del Parque Nacional del Teide (Figura 1.1). Para poder operar con la información que contiene es necesario realizar una secuencia de operaciones de preprocesado que permitan obtener primero la reflectividad superficial de la imagen y, posteriormente, aplicar las correcciones pertinentes para obtener un

buen resultado sobre el que aplicar las diferentes metodologías de clasificación. Estas correcciones se describen con más detalle a continuación.

Procesado Radiométrico. En esta etapa se lleva a cabo el proceso de obtención de la reflectividad superficial a partir de los datos de irradiancia adquiridos por el sensor. En este punto, cabe destacar que la firma espectral de la imagen, inicialmente, contenía picos incoherentes en diferentes partes del espectro de la imagen provocados por la reflectancia atmosférica.

Procesado Geométrico. Usando un Modelo Digital del Terreno, DEM, de alta resolución se procede a la ortorectificación para eliminar las posibles distorsiones geométricas debidas a errores de posicionamiento o a variaciones de distinta naturaleza, como variaciones topográficas.

Corregistro de hipercubos. Debido a que la obtención por parte del sensor fue realizada con barridos del dron sobre el área capturada, la imagen final está compuesta por tiras de imágenes obtenidas en cada barrido. Por esta razón, los hipercubos presentan errores elevados aún habiendo obtenido un DEM de alta calidad. Para resolverlos, se realizó un corregistro en el cual se ajustan las imágenes a las ortofotos disponibles del modelo de fotogrametría disponible del PNT.

Mosaicado. En este punto ya se han obtenido los resultados de reflectividad corregistrados y ortorectificados. Básicamente, esta etapa consiste en juntar las tiras hiperespectrales y formar así la imagen final.

Postprocesado. Fue necesario hacer uso de técnicas de relleno de zonas de la imagen con la ayuda de la información del entorno, pues errores provocados por pequeñas vibraciones o desplazamientos del sensor pasan desapercibidos a los procesos de ortorectificación y corregistro.

A pesar de que el resultado del preprocesado y de la ortorectificación fueron satisfactorios, se deben tener en cuenta algunos inconvenientes irresolubles en esta etapa, como por ejemplo solapes apreciables resultantes del mosaicado de la imagen o longitudes de onda cuya irradiancia es muy pequeña, lo cual implica valores de reflectividad con un alto umbral de ruido. Por esta última razón fueron eliminadas de la imagen las longitudes de onda correspondientes al rango 900 nm -

1000 nm. Por otro lado, se ha de tener en cuenta que las imágenes hiperespectrales obtienen radiación en anchos de banda muy reducidos, por lo que el sistema debe calcular automáticamente la mejor cuantificación de los datos según el área barrida. Este hecho puede implicar que ciertos valores de reflectividad saturan al ser esta muy alta. Esto último tiene una importante relevancia a la hora de calcular VI, como se verá en secciones posteriores (3.4).

A pesar de que las operaciones llevadas a cabo en la etapa de preprocesado tratan de adecuar en la medida de lo posible la imagen para su tratamiento posterior, existen fenómenos perjudiciales que no fueron corregidos con las operaciones anteriores. Por ello, ha sido necesario incluir otra etapa a la cadena de preprocesado en la cual se han solventado estos defectos de la manera a continuación descrita.

Supresión de bandas espectrales anómalas. Debido a que la absorción atmosférica se manifiesta principalmente en longitudes de onda situadas en torno a los 760 nm, aparecen picos de reflectividad que no son coherentes con la continuidad de la firma espectral. Para corregirlos, se han eliminado las bandas afectadas por este fenómeno, eliminando dichos picos a costa de perder bandas espectrales en una región en la que la vegetación manifiesta características importantes, (*Red Edge*). Concretamente se han eliminado 5 bandas (86, 87, 88, 89 y 90) correspondientes a la región espectral de 752 nm - 769 nm. Se ha empleado para ello la herramienta *Resize*, disponible en ENVI.

Recorte y registrado. Dado que la variedad de vegetación capturada está limitada a las tres especies de interés que aparecen en la imagen y su cantidad es bastante uniforme a lo largo y ancho del área total capturada, se ha decidido realizar el trabajo de clasificación y análisis sobre un recorte de la imagen preprocesada (Figura 3.3). Así, se han reducido sustancialmente los tiempos de cómputo y ha sido posible poner a prueba diferentes formas de clasificar imágenes hiperespectrales. Se dispone adicionalmente de una imagen RGB captada por un dron con una resolución espacial de 1 cm, cuyo tamaño ha determinado el tamaño del recorte realizado sobre la imagen hiperespectral. Tras realizar este recorte ha sido necesario registrar la imagen con respecto a la imagen RGB, que ha sido tomada de la misma zona y desde la mismo

perspectiva. El recorte ha sido realizado haciendo uso de la herramienta *Review and Wrap* y el registrado posterior con *Image Registration Workflow* de ENVI.




Figura 3.3: Imagen obtenida por el dron y el recorte seleccionado para este Trabajo.

Al final de este proceso, la imagen resultante tiene las características representadas en la Figura 3.4.




Figura 3.4: Imagen preprocesada y características principales.

3.3. Selección de datos de entrenamiento y evaluación

Como se ha podido contemplar en la sección 2.2, existen dos tipos de clasificación aplicables a problemas como el que nos concierne, conocidos como clasificación supervisada y no supervisada. Todos los procedimientos de clasificación implementados en este Trabajo responden a un modelo de clasificación supervisada, en el cual los datos de entrenamiento que se utilizarán serán seleccionados manualmente, siguiendo pautas visuales que permiten identificar objetivamente las diferentes clases que conformarán los grupos de entrenamiento.




Figura 3.5: Clases que compondrán los distintos conjuntos de datos de entrenamiento.

Los grupos de entrenamiento contendrán todas las superficies que aparecen en la imagen, de manera que cada una de ellas se asignará a su clase correspondiente. Así, las clases que componen los grupos de entrenamiento son, como especies vegetales vivas, la retama (*Spartocytisus supranobius*), el rosalillo de cumbre (*Pterocephalus lasiospermus*) y la hierba pajonera (*Descurainia bougaeana*), y, como superficies muertas, el suelo y la vegetación muerta. Las diferentes clases seleccionadas se pueden ver en la Figura 3.5.

Para otorgarle más robustez a la clasificación, teniendo en cuenta que la imagen no está tomada bajo un patrón lumínico uniforme al estar compuesta por diferentes tiras, se ha considerado conveniente crear varios grupos de entrenamiento formados por las

mismas clases, pero seleccionando píxeles distintos de cada una. De esta manera se pretende reducir las posibles confusiones producidas por las diferentes tonalidades que pueden tener los píxeles de cada clase debidas, por ejemplo, a las sombras, a la dirección de incidencia de la luz sobre el elemento en cuestión o a diferencias de tonalidad en función del estado de salud de la vegetación. Concretamente, se han creado 5 grupos de entrenamiento y evaluación, cuyas denominaciones serán: *ROI_1*, *ROI_2*, *ROI_3*, *ROI_4* y *ROI_5*. De esta manera, cada clase, en cada conjunto, queda definida por el número de píxeles seleccionados (Tabla 3.1) y su correspondiente firma espectral (Figura 3.6). Específicamente, se representa el valor medio para cada clase y conjunto de datos.

Tabla 3.1: Número de píxeles de cada ROI y cada clase.

Clase	<i>ROI_1</i>	<i>ROI_2</i>	<i>ROI_3</i>	<i>ROI_4</i>	<i>ROI_5</i>
Retama	2826 px	4027 px	7107 px	1776 px	2623 px
Rosalillo	2518 px	4111 px	2614 px	1711 px	2625 px
H. Pajonera	2067 px	4044 px	3369 px	1458 px	2659 px
Suelo desnudo	2426 px	4244 px	6240 px	1617 px	2690 px
Veg. Muerta	2423 px	4051 px	3545 px	2026 px	1638 px
Total	12260 px	20477 px	22938 px	8588 px	12235 px

Las firmas espectrales de cada conjunto (Figura 3.6) son muy similares, pero no idénticas. Así, promediando los datos de precisión obtenidos con cada una de ellas en cada operación de clasificación, se le otorgará mayor robustez a la metodología. Visualmente, se pueden sacar las siguientes conclusiones a partir de las firmas espectrales.

- Las clases no vegetales muestran firmas espectrales muy distintas con respecto a las firmas de las clases vegetales, lo cual indica, a priori, que la clasificación será capaz de separar vegetación del resto sin demasiada confusión, aunque se puedan esperar píxeles erróneos en píxeles correspondientes a zonas de la imagen de mucha vegetación muerta en el centro de una retama, por ejemplo.
- La firma espectral de las diferentes clases de vegetación siguen un patrón similar. Como se puede apreciar en la Figura 3.6, estas firmas siguen un patrón coherente con el de la mayoría de especies vegetales con altos contenidos de clorofila. Además, por su parecido visual y espectral caben esperar píxeles confusos entre la retama y el rosalillo.
- La hierba pajonera muestra una firma espectral ampliamente diferenciable de las firmas del resto de vegetación en la mayoría del espectro representado en la




Figura 3.6: Firmas espectrales de cada conjunto de datos de entrenamiento.

imagen. Por ello, cabe esperar buena separación entre la hierba pajonera y el resto de vegetación. De forma particular, al ser de color amarillo, la energía para su actividad fotosintética la obtiene absorbiendo la radiación en longitudes de onda de la transición de verde (590 nm) a rojo (640 nm) y refleja gran parte la radiación correspondiente a las longitudes de onda del azul (450 nm) y verde (590 nm). En este análisis se deben detectar parámetros clave para diseñar algoritmos de separación de clases (segmentación) basados en árboles de decisión (DT). Como se verá en la Sección correspondiente al cálculo de VIs más adelante, si se emplea un resultado del índice en cuestión para establecer un umbral con el que comparar y clasificar el valor de cada píxel, se pueden calcular umbrales operando con las reflectancias que permitan la separación de una clase de forma precisa.

Sin embargo, no es posible validar estos conjuntos de entrenamiento si no se evalúa previamente cuán bien separan espectralmente cada una de las clases que los componen.

Para ello, es posible realizar un análisis de separabilidad en ENVI. Este análisis realiza una operación basada en estudiar la distancia espectral entre los valores de los píxeles que componen las clases para dar como resultado una matriz en la que se muestren todas las clases emparejadas y relacionadas por un valor conocido como *Transformed Divergence* (TD), que será un valor entre 0 y 2. Parejas con valores mayores a 1,9 se consideran buenas a efectos de separabilidad y menores a 1 no se considerarán aptos para entrenar o validar el conjunto.

Los resultados de las matrices de *Transformed Divergence - Jeffrey Mattusitu* (TD) obtenidos para los conjuntos de entrenamiento y evaluación con los que se realizará la clasificación se representan en la Tabla 3.2.

Tabla 3.2: Matriz de separabilidad (TD) para cada par de clases.

<i>Clases</i>	<i>ROI_1</i>	<i>ROI_2</i>	<i>ROI_3</i>	<i>ROI_4</i>	<i>ROI_5</i>
Retama - Rosalillo	1,997404	1,981690	1,998657	1,999540	1,997778
Retama - H. pajonera	1,999993	1,999974	2,000000	2,000000	2,000000
Retama - Veg. muerta	1,999522	1,999545	1,999992	1,999995	1,999656
Retama - Suelo	2,000000	2,000000	2,000000	2,000000	2,000000
Rosalillo - Pajonera	1,999260	1,999918	1,999981	1,999998	1,999978
Rosalillo - Veg. Muerta	1,999317	1,998719	1,999919	1,999986	1,996731
Rosalillo - Suelo	2,000000	2,000000	2,000000	2,000000	1,999994
Pajonera - Veg. muerta	1,999997	1,999997	1,999998	2,000000	1,999997
Pajonera - Suelo	2,000000	2,000000	2,000000	2,000000	1,999994
Suelo - Veg. muerta	1,999982	1,999963	1,999995	2,000000	1,999561

Finalmente, habiendo comprobado las firmas espectrales de los grupo de datos de entrenamiento, y analizado la separabilidad entre las clases que los componen, se puede validar su proceso de selección y creación. Serán estos conjuntos de datos con los que se aplicarán las todas las metodologías de clasificación. Como se puede compobar en la Tabla 3.2 los valores de separabilidad aseguran que los píxeles de cada clase están bien definidos, a priori, para no generar confusión ellas, facilitando así la operación de clasificación. Cabe esperar que las clases con menor separabilidad serán la retama y el rosalillo. No obstante, los valores de separabilidad obtenidos en la tabla son cercanos al máximo que determina una separación perfecta.

3.4. Cálculo de índices de vegetación

Aprovechando la característica hiperespectral de la imagen disponible, se han calculado una serie de Índices de Vegetación (VI). El propósito de su cálculo persigue dos objetivos diferenciados que le confieren especial importancia en desarrollo de este Trabajo. Por un lado, la función general del índice es detectar algún estado de la vegetación a través del análisis sobre la reflectividad superficial medida en cada longitud de onda del rango espectral disponible en la imagen. Por otro, aplicando los datos de entrenamiento sobre los índices calculados, se podrá comprobar la distribución de valores que cada índice le asigna a cada clase, de forma que se pueda establecer un umbral a través del cual separar las diferentes clases, a través de un algoritmo basado en árboles de decisión creados a partir de los resultados de estos índices. Por tanto, estos dos objetivos se pueden resumir en lo siguiente:

- Monitorizar el estado de la vegetación analizada en la imagen y detectar posibles estados anómalos de las plantas que manifiestan las plantas en el espectro de la radiación solar reflejada.
- Permitir crear metodologías de clasificación fundamentadas en los resultados obtenidos a partir de los Índices de Vegetación (*thresholding* & *layer stacking*).

ENVI dispone de una herramienta diseñada expresamente para el cálculo de VI que además ofrece la posibilidad de hacerlo de forma sencilla, puesto que la expresión matemática de cada índice ya está predefinida en el software, a través de una herramienta llamada *Vegetation Index Calculator* (VIC). Sin embargo, como se ha descrito en la sección 3.3, hay valores de reflectividad que saturan bajo ciertas condiciones expuestas en la imagen y, como esta herramienta realiza el cálculo de cada índice de manera interna (opaca al usuario), que detalla el *software* en su documentación [5].

Atendiendo a las advertencias observadas en el preprocesado de la imagen, se ha considerado conveniente calcular cada uno de los índices de manera que cada expresión matemática y cada longitud de onda empleadas sean introducidas de forma manual. Así se podrá tener control de cada uno de los pasos llevados a cabo para el cálculo. Para ello, ENVI ofrece la posibilidad de hacerlo mediante una herramienta llamada *Band Math* (BM). Los procedimientos de cálculo se pueden ver en las Figuras 3.7 para VIC, y 3.8, para BM.




Figura 3.7: Diagrama de aplicación de la herramienta *Vegetation Index Calculator* de ENVI.




Figura 3.8: Diagrama de aplicación de la herramienta *Band Math* de ENVI.

Los índices aplicados son los descritos en la Sección 2.3. No obstante, para dejar constancia de la diferencia encontrada en la aplicación de las dos herramientas anteriormente descritas, se debe tener en cuenta que, para que la herramienta VIC funcione correctamente, es necesario emplear máscaras que eliminen toda aquella superficie no vegetal, pues esta herramienta no asigna valores a las zonas de suelo desnudo y vegetación muerta, como se puede comprobar en la Figura 3.9. Como interesa especialmente emplear los índices de vegetación también para clasificar la imagen por diferentes metodologías se ha optado por calcular todos los índices de vegetación de forma manual con BM.

Con todos los mapas de valores de VIs calculados, se puede realizar un análisis visual (Figura 3.10) para estimar si un índice, aparentemente, discrimina entre las




Figura 3.9: Ejemplo de resultado del cálculo del índice ARVI con BM y VIC.

distintas clases pero no es posible extraer información suficiente para realizar un análisis detallado de como pondera dicho índice los píxeles de las diferentes clases, ni tampoco se puede concluir aún si el índice cumple el propósito para el cual está definido. Sin embargo, se puede estudiar numéricamente el valor que cada índice le asigna a cada píxel y como son los valores que caracterizan cada clase.

Como se ha comentado anteriormente, la funcionalidad buscada de estos índices no sólo se corresponde con analizar el estado de la vegetación expuesta en la imagen, sino que también permite comprobar el comportamiento de cada uno de ellos para separar clases (vegetales o no). Para evaluar esta capacidad, se ha hecho uso de los cinco conjuntos de datos de entrenamiento seleccionados en el apartado anterior, una vez han sido calculados los índices. Al aplicar un conjunto de datos sobre la imagen de cada índice, es posible obtener los valores resultantes de cada píxel para cada una de las clases. De esta forma, se obtiene una distribución formada por el valor de la muestra digital (valor de píxel) y el número de veces que aparece ese valor en dicha distribución. Además de poder obtener los valores máximo, mínimo, media y desviación estándar (y por tanto, varianza, covarianza, etc.), con los cuales se realizará el análisis cuantitativo




Figura 3.10: Ejemplos de mapas obtenidos tras el cálculo de Índices de Vegetación (VIs).

de la información relativa al propósito general del índice (caracterizar algún parámetro relacionado con el estado de la planta), es posible utilizar los resultados obtenidos para separar diferentes clases (clasificar), si los rangos de valores de esas clases no se solapan. El procedimiento por el cuál se realiza esta separación de clases consiste en estudiar, tratando de maximizar la precisión, como se distribuyen los valores del índice evaluado en cada clase y establecer un umbral de separación que permita clasificar dicha imagen (*thresholding*). Para caracterizar los índices, de manera que se facilite su análisis, se han empleado diagramas de caja (*boxplots*) de los valores de cada clase y se han seleccionado los índices que permitan la separación más óptima.

El procedimiento por el cual se han obtenido los diagramas de cajas de cada clase para cada índice se puede enumerar en los siguientes pasos (Figura 3.11):

1. A la imagen del índice, se le aplican los datos de entrenamiento. El proceso se ha realizado de forma análoga para los 5 conjuntos de datos creados en la Sección 3.3.
2. Se extraen las estadísticas del índice para cada una de las clases (Herramienta




Figura 3.11: Procedimiento de obtención de *boxplots*.

Region of Interest, opción *Compute statistics from ROIs*).

3. Se procesan los resultados obtenidos en el punto anterior. Para ello, ENVI proporciona un fichero de estadísticas con los valores digitales de cada píxel (DN) separados por clases, y el número de veces que aparece ese valor en la imagen (Npts). Además, resume los valores anteriores dando el valor mínimo, el máximo, la media y la desviación estándar de la distribución; no obstante, para calcular los *boxplots* son necesarios todos los valores, pues interesa ver de qué manera están distribuidos según el número de veces que aparecen. Por tanto, haciendo uso del software Matlab, se ha diseñado un procedimiento por el cual se extraen los valores del fichero de texto (DN y Npts), se forman los arrays correctamente, y se calculan los *boxplots* (Se adjunta el código desarrollado en el Anexo I).

A modo de ejemplo, en la Figura 3.12 se representan los *boxplots* correspondientes a 5 VIs evaluados concretamente con la *ROI_2*. Se puede apreciar como, aparentemente, la separación entre las clases responde a las firmas espectrales obtenidas (Figura 3.6) y se debe hacer mención al número de valores espúreos (*outliers*) resultantes en todas las clases de prácticamente todos los VIs, pues en algunos casos es tan elevado que no es conveniente despreciarlo. Las conclusiones que se pueden sacar de la observación de las Figura 3.12 son las siguientes:

- El rosalillo y la retama coinciden altamente en el mismo rango de valores, lo cual advierte de la dificultad que tendrán los diferentes algoritmos de clasificación para la separación de ambas clases.
- El suelo, en la mayoría de los índices, es separable de la vegetación muerta, aunque para que esta separación sea eficiente sería recomendable separar, previamente, las clases vegetales de las no vegetales con índices como por ejemplo NDVI.

- Todos los índices presentan píxeles espúreos. En algunos casos, la cantidad de los mismos puede afectar en la detección de un umbral de separación entre clases.




Figura 3.12: *boxplots* de índices evaluados con *ROI2*.

Al final de este procedimiento se tienen los resultados de los VI aplicados, y los *boxplots* de cada índice generado con cada grupo de datos de entrenamiento. En total, 16 mapas de índices de vegetación de la imagen hiperespectral y 80 (16x5) *boxplots* que darán información acerca de cómo cada índice separa cada una de las diferentes clases. No obstante, se ha creado un VI específico aprovechando un matiz observado en las firmas espectrales de los datos de entrenamiento generados en la Sección 3.3. Se fundamentación y el procedimiento llevado a cabo para su obtención se definen a continuación.

Creación de un Índice de Vegetación específico para caracterizar la hierba pajonera.

Analizando las firmas espectrales obtenidas de cada uno de los grupos de entrenamiento (Figura 3.6), se pudo comprobar como la hierba pajonera era la única clase vegetal que mostraba un comportamiento espectral distinto a las demás en ciertas longitudes de onda. Pues bien, teniendo en cuenta que los VI hiperespectrales se caracterizan por operar con la reflectividad de bandas espectrales específicas, se ha podido diseñar un VI específico que permita discriminar la hierba pajonera. Para ello, analizando la firma espectral de de las diferentes clases, se han seleccionado dos bandas

a través de las cuales se puede obtener un índice de vegetación en el que los valores de reflectividad de la hierba pajonera, previsiblemente, deberían ser mayores que en el resto de clases (Figura 3.13).




Figura 3.13: Firma espectral para crear YNDVI.

La definición de este índice pretende establecer una relación normalizada entre la reflectividad superficial contenida en una longitud de onda perteneciente a la región espectral cercana a la del color azul (479.29 nm) y en otra longitud de onda situada aproximadamente en el borde entre el color verde y amarillo (566.01 nm). Se le ha denominado con el nombre *Yellowness Normalized Difference Index* y su expresión matemática es la siguiente:

$$\text{YNDVI} = \frac{\rho_{566} - \rho_{479}}{\rho_{566} + \rho_{479}}$$

Para su cálculo, al igual que para todos los índices anteriores, se ha empleado la herramienta *Band Math* de ENVI, y el resultado ha sido el representado en la Figura 3.14, en la que la hierba pajonera es la clase de color amarillo. Realizando un análisis visual sobre esta figura se puede estimar que el índice cumple con el propósito principal por el que fue creado, separar la hierba pajonera del resto de clases, pues los valores de hierba pajonera del VI (área de color amarillo) se corresponden, de forma aparente, con la hierba pajonera de la imagen original.

Tras calcular los *boxplots* aplicando los conjuntos de datos de entrenamiento (3.3), de la misma forma que con todos los demás VI, se puede concluir que el índice de vegetación creado permitirá separar mejor la clase hierba pajonera de todas las demás, en un posterior proceso de clasificación consistente en aplicar árboles de decisión a los





Figura 3.14: Mapa de valores de YNDVI.

resultados de los VI. Los resultados obtenidos se representan en la Figura 3.15, y como se puede comprobar, la hierba pajonera queda caracterizada por valores mayores a las demás clases, con todos los grupos de entrenamiento.

Figura 3.15: *Boxplots* de YNDVI con todos los grupos de entrenamiento.

En resumen, de todo el proceso de cálculo de los VI, la información obtenida se puede cuantificar en una mapa de valores con los resultados de cada índice, o lo que es lo mismo, una imagen, y un fichero con los resultados estadísticos de aplicar sobre ella cada uno de los conjuntos de entrenamiento (17 imágenes y 85 ficheros estadísticos).

3.5. Clasificación de la imagen hiperespectral

En este apartado, se genera la mayor parte del material cartográfico obtenido en este Trabajo, además de evaluar qué algoritmo de clasificación consigue separar las clases con mayor precisión, lo cual además será importante para crear las máscaras que permitirán focalizar el estudio sobre la retama. Como se ha comentado anteriormente, se ha empleado una metodología basada en la implementación de distintos algoritmos de clasificación supervisada sobre la imagen hiperespectral, en la que los datos de entrenamiento y evaluación utilizados han sido los generados en la Sección 3.3. Los procesos de clasificación llevados a cabo se han realizado en ENVI, capacitado de una interfaz de clasificación que permite aplicar una gran variedad de clasificadores definidos en el *software* con tiempos de cómputo que, con el *hardware* disponible, son reducidos. Además, dispone de las herramientas necesarias para clasificar imágenes a partir de los VI y para extraer información fundamental en relación a la validación de los procesos de clasificación. Concretamente, para lo primero se han empleado árboles de decisión fundamentados en umbralizar diferentes índices en función de su comportamiento para separar clases y, para lo segundo, se han obtenido las matrices de confusión de cada imagen clasificada con los diferentes conjuntos de datos de entrenamiento y evaluación. Sin embargo, la cantidad de información obtenida a partir de estas matrices ha requerido la implementación de diferentes herramientas que permitan procesarla y analizarla de forma eficiente.

En primer lugar se detallará el procedimiento empleado para la aplicación de los diferentes algoritmos de clasificación disponibles en ENVI. Posteriormente, se describirá cómo a partir los VIs calculados en la Sección 3.4 se pueden aplicar metodologías de separación de clases de una imagen. Por un lado se han separado las diferentes clases haciendo uso de árboles de decisión que categoricen los valores de los diferentes índices y por otro, se han aplicado los algoritmos de clasificación que mejor resultado han dado anteriormente sobre la imagen hiperespectral, a una imagen cuyas bandas son los VIs seleccionados. Todos los procesos de clasificación han sido aplicados utilizando como datos de entrenamiento los conjuntos seleccionados en la Sección 3.3.

En resumen, al final de esta Sección se dispondrán de todos los mapas de clasificación obtenidos por las tres metodologías descritas.

3.5.1. Clasificación empleando las bandas hiperspectrales

El primer proceso de clasificación ha consistido en aplicar, sobre la imagen hiperspectral, una selección de seis métodos de clasificación supervisada, empleado para ello los datos de entrenamiento definidos anteriormente (Sección 3.3). El desarrollo de esta metodología de clasificación se puede ver representado en la Figura 3.16, en la cual se muestran también los algoritmos de clasificación aplicados, cuya definición teórica ha sido explicada en la Sección 2.2.

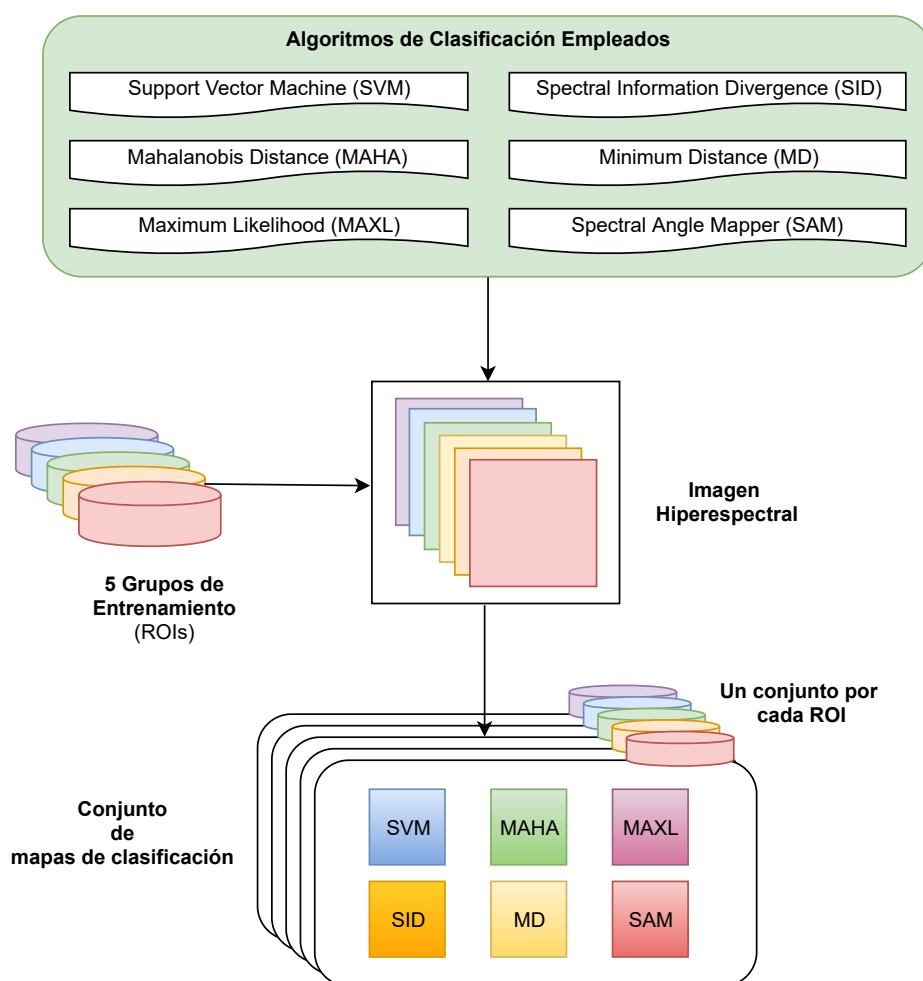


Figura 3.16: Aplicación de algoritmos de clasificación sobre imagen hiperspectral.

Los algoritmos de clasificación han sido aplicados con cada uno de los conjuntos de datos de entrenamiento por separado. De esta manera, calculando cinco mapas clasificados con el mismo método pero con datos de entrenamiento distintos, se obtendrá información suficiente para poder validar los mapas resultantes. De forma que, tras obtener cinco resultados por clasificador, se pueda concluir si los datos de precisión obtenidos para cada uno de ellos son suficientemente robustos. Esto es, la precisión de

clasificación obtenida para cada caso resulta en un rango de valores similar y cada clase ha sido separada sin cometer errores de confusión abultados en el proceso, con lo cual también será posible reforzar la validación del proceso de selección de cada conjunto de datos de entrenamiento. Bajo este criterios se ha concluido si una clasificación queda validada o, por el contrario, se descarta de los resultados finales.

Antes de analizar el proceso de validación llevado a cabo, se describirá el procedimiento por el cual han sido aplicados los diferentes clasificadores. Como ya se ha comentado, ENVI dispone de los algoritmos de clasificación supervisada implementados y permite su aplicación a través de una interfaz. Los pasos seguidos para la obtención de cada mapa clasificado son los representados en la Figura 3.17:

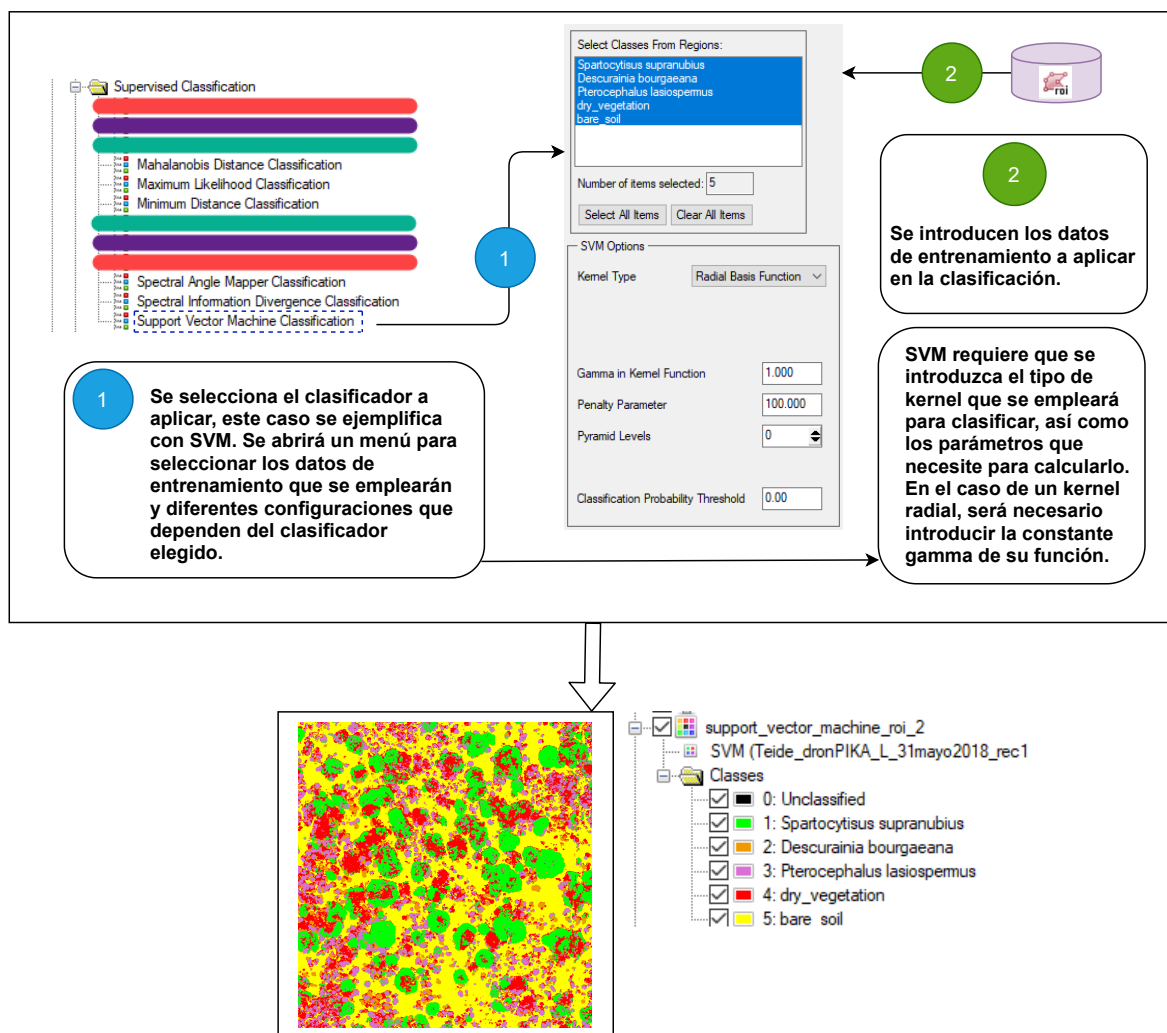


Figura 3.17: Proceso de aplicación de SVM sobre imagen hiperespectral.

- Con la imagen hiperespectral y el conjunto de datos de entrenamiento preparados, en el menú *Supervised Classification* se seleccionará el método de clasificación que

se pretenda aplicar (en el ejemplo de la Figura 3.17, se ha seleccionado el SVM).

- Seguidamente se seleccionan los datos de entrenamiento con los que se realizará la clasificación y otros datos importantes según el clasificador aplicado. En el caso de SVM, se debe seleccionar el tipo de kernel a emplear y sus parámetros específicos. En todas las clasificaciones con SVM se ha empleado un kernel de función de base radial con una constante *gamma* igual a uno.
- En este punto, con la clasificación ya realizada y el mapa resultante disponible, en una etapa de posclasificación posterior ha sido aplicada un procesado adicional conocido como *Majority Analysis*, cuyo fundamento es emplear un kernel gaussiano, cuya estructura es una matriz de dimensiones impares, para escanear el mapa píxel a píxel, en el que el píxel central del kernel será remplazado por el valor de la clase que tenga mayoría en los píxeles del mismo. Con esta operación se pueden corregir gran parte de los píxeles aislados erróneos mejorando significativamente la precisión de la clasificación. El tamaño definido para el kernel se ha ajustado individualmente para cada clasificador en función de la cantidad de píxeles que ha confundido, para el SVM, se ha empleado un kernel de tamaño 5x5.

Este proceso se realizará tantas veces como conjuntos de datos de entrenamiento se tengan en disposición, de tal manera que la validación del proceso de clasificación con un clasificador determinado dependa del resultado obtenido para todos los conjuntos de entrenamiento empleados. Si un clasificador da resultados significativamente distintos con un conjunto determinado, se descartará del proceso o el clasificador o el conjunto de datos empleados para clasificar según se detecte cual de ellos ha tenido más influencia en el resultado negativo obtenido.

La evaluación de los diferentes mapas clasificados se realizará a través de una herramienta conocida como *matriz de confusión*. Esta operación permite analizar de forma detallada el mapa clasificado mediante la comparación, clase a clase, de los resultados obtenidos con unos valores de referencia supuestamente verídicos. En el apartado correspondiente al análisis de los resultados obtenidos (Sección 3.6), se explicará detalladamente la estructura de esta matriz de confusión y los parámetros que se utilizarán, tanto para validar cada mapa de clasificación presentado en el resultado final como para

evaluar la precisión obtenida con cada clasificador. Si bien esto último será determinado promediando los resultados de cada clasificador con cada uno de los datos de entrenamiento, la validación depende de que los cinco mapas clasificados de cada clasificador den resultados coherentes, luego las matrices de confusión serán empleadas para evaluar cada mapa clasificado. De forma introductoria al posterior análisis, la precisión y el coeficiente kappa obtenidos para cada clasificador, calculados promediando los valores de estos parámetros obtenidos con cada conjunto de datos de entrenamiento se muestran en la Tabla 3.3.

Tabla 3.3: Resultados de clasificación promediados entre los 5 grupos de entrenamiento y evaluación.

Clasificador	<i>Ov. Accuracy</i>	<i>Kappa Coeff.</i>
SVM	95,8740 %	0,9480
MAXL	94,9167 %	0,9380
MAHA	93,7288 %	0,9258
SID	89,5798 %	0,8650
MD	76,1586 %	0,7051
SAM	75,6200 %	0,7074

En base a estos resultados, se puede concluir que a efectos de precisión global, los clasificadores con los cuales se han obtenido mejores resultados son SVM, MAXL y MAHA. Si bien los mapas clasificados que se incluirán en el resultado final del proceso de generación de cartografía del ecosistema serán los obtenidos con estos tres clasificadores (Figura 3.18), los demás mapas no serán descartados por no realizar el proceso con una precisión aceptable, ya que su aplicación permite estudiar el comportamiento que muestra cada clasificador al ser empleado para separar las distintas superficies del entorno vegetal representado en la imagen hiperespectral disponible. De manera que en futuros estudios, se pueda tener conocimiento de como se comporta el mayor número de clasificadores posible al ser aplicados a imágenes de características similares a la disponible y del mismo ecosistema.




Figura 3.18: Mapas clasificados con MAHA, SVM y MAXL.

3.5.2. Clasificación empleando árboles de decisión basados en VIs

En este apartado se describe la aplicación de una metodología de clasificación de la imagen haciendo uso de la información obtenida de los VI calculados en la Sección 3.4. Es importante para ello que se disponga de la información calculada de manera que sea posible caracterizar de forma precisa las distintas clases que componen los grupos de entrenamiento. Los diagramas de caja (*boxplots*) generados en la sección anterior sirven a este propósito de forma eficiente, pues permiten encontrar valores específicos del índice que permitan realizar un proceso de dicriminación entre las clases de la imagen.

La posibilidad de llevar a cabo esta metodología subyace de la cantidad de VIs calculados. Pues se observa, realizando un análisis de la información obtenida a través de los *boxplots*, que se pueden obtener valores suficientes para separar todas las clases y así obtener una imagen completamente clasificada. Al algoritmo que permitirá clasificar la imagen se le denominará a partir de ahora como árbol de decisión.

En el contexto de este trabajo, se entiende por un árbol de decisión una relación de condiciones booleanas (nodos) concatenadas aplicadas sobre los valores de un VI a través de la cual es posible determinar a qué clase pertenece. Los valores específicos de cada nodo serán umbrales calculados a partir del análisis de la información estadística de los VI y, serán estos umbrales, los que determinarán la precisión con la que se ejecuta la clasificación final. El diseño de los árboles de decisión desarrollados en este apartado responde al esquema representado en la Figura 3.19 y todos los árboles aplicados tendrán la misma estructura, con diferentes índices y umbrales.

Por como representan la información los *boxplots*, resulta sencillo comprobar que se pueden establecer umbrales que permitan discriminar entre distintas clases. La precisión con la que sean elegidos estos umbrales determinará cuán buena es la clasificación, por lo que se ha de establecer una metodología para que, en todos los nodos, el mecanismo por el cual se calcula un umbral resuelva de la manera correcta los píxeles más cercanos a él. En principio, los criterios bajo los cuales se considera que un VI es apto para umbralizar son los siguientes:

1. Si las clases representadas no coinciden en ningún valor (se permiten valores




Figura 3.19: Árbol de decisión genérico.

outliers, pues se considera que introducen un error tolerable), las clases serán perfectamente separables, ya que el número de píxeles que coinciden en valor digital es despreciable con respecto al número de píxeles que componen la distribución (Figura 3.20a).

2. En el caso de que la coincidencia venga dada por valores no correspondientes al Rango Intercuartílico (IQR) de cada clase, se considerará que se puede umbralizar de forma que el número de píxeles de confusión sea, en la medida de lo posible, igual para cada una de las clases que se quieren separar. Por ejemplo, en la Figura 3.20b, las clases 3 y 4 se solapan por encima del tercer cuartil y por debajo del primer cuartil respectivamente. Luego para establecer el umbral de separación se calcula el valor medio entre el valor máximo de, en este caso, la clase 3 y el valor mínimo de la clase 4 (sin incluir los valores *outliers*). Se ha de tener en cuenta que, posiblemente, se está cometiendo un pequeño error en la umbralización siguiendo este método, pues calcular los umbrales obteniendo el valor medio entre dos límites no implica, en este caso, que se esté caracterizando el punto en el que

se reparten los errores de forma equitativa. Los *boxplots* representan los valores entre los cuales se reparten los píxeles de cada clase, pero no aportan información suficiente para determinar exactamente como están distribuidos entre esos valores. Para poder visualizar de qué forma están distribuidos los valores de las distintas clases se han empleado representaciones de los histogramas de cada una. En la Figura 3.21 se muestran varios ejemplos de los histogramas de dos clases representados sobre la misma gráfica (Clases A y B).

3. Si los IQR de las clases representadas se solapan para un determinado VI, se considerará inviable la umbralización, pues no será posible encontrar un valor umbral sobre el cual, el error cometido en la clasificación sea tolerable (Figura 3.20c).




Figura 3.20: *Boxplots* de diferentes clases para un VI.

Aprovechando que se han obtenido resultados para cinco grupos de entrenamiento, se ha decidido crear un árbol de decisión con cada uno de ellos. No obstante, las posibilidades de crear distintos árboles si se combinan *boxplots* de grupos distintos son demasiadas para ser evaluadas en el tiempo disponible para la realización de este Trabajo. El objetivo entonces se basa en tratar de presentar una metodología que permita realizar clasificaciones con resultados aceptables. Los árboles de decisión que




Figura 3.21: Histogramas de diferentes clases para un VI.

se han generado siguen el esquema presentado en la Figura 3.19 y se describen a continuación. Si bien cada uno de ellos emplea distintos umbrales, de distintos índices, las condiciones impuestas en cada nodo resuelven las mismas clases.

- Inicialmente, se considera indispensable separar las clases de vegetación de las clases no vegetales.
- Una vez realizada la umbralización anterior, se ha buscado el índice que mejor separe las clases *suelo desnudo* y *veg. muerta*.
- A continuación, la umbralización de las clases vegetales se va a realizar en dos pasos. Primero se separará la *hierba pajonera* de las otras dos clases vegetales.
- Por último, la separación que ha presentado más dificultad, debido a la similitud existente entre sus respectivas firmas espectrales, ha sido la de *retama* y *rosalillo*. Ningún índice de los calculados ofrece una separación ideal, por lo tanto, se ha seleccionado, en cada caso, aquel en el que haya un menor solape de los valores.

A partir de aquí queda definir los diferentes nodos que compondrán el árbol con los umbrales calculados en cada caso. Para ejemplificar el procedimiento de creación de un

árbol de decisión se ha descrito detalladamente la rutina llevada a cabo para obtener la imagen clasificada con los datos de entrenamiento de la *ROI_2*, desde el cálculo de los umbrales que compondrán las condiciones del árbol, hasta la creación y aplicación del mismo. Aplicando el mismo procedimiento se han obtenido cinco imágenes clasificadas, cada una de ellas con un árbol de decisión umbralizado empleando un conjunto de datos de entrenamiento distinto.

Para el grupo de datos *ROI_2*, observando los *boxplots* obtenidos de los 17 índices de vegetación, se ha hecho una selección de aquellos que mejor separan las diferentes clases en el orden establecido en la Figura 3.19. Los *boxplots* de los índices que se han utilizado para este procedimiento se pueden ver en la Figura 3.22 y los umbrales se han calculado como se describe a continuación.

- El mejor índice de vegetación para separar las clases vegetales de las no vegetales ha resultado ser MRENDVI. En la Figura 3.22a se puede apreciar gráficamente la umbralización para separar las clases *suelo desnudo* y *veg. muerta* con respecto a las demás. El umbral se calcula haciendo uso del valor mínimo del rosalillo y el valor máximo del suelo desnudo, sin tener en cuenta los valores *outliers*. Contrastando con el histograma correspondiente a las clases *veg. muerta* y *rosalillo*, se ajusta el valor finalmente seleccionado (Tabla 3.4).
- Las dos clases no vegetales se separarán umbralizando el índice PRI (Figura 3.22b). Para ello, se calcula el valor medio entre el mínimo de la Veg. Muerta y el máximo del Suelo. Se puede apreciar en el histograma 2 que, salvo unos pocos píxeles, la separación es muy buena entre estas dos clases y el umbral seleccionado se encuentra en la zona de máximo solape entre las dos clases.
- Las clases vegetales, según la Figura 3.19, serán umbralizadas dos veces. En la primera de ellas se separa la H. pajonera del resto de vegetación. Haciendo uso del *boxplot* obtenido para YNDVI, se puede establecer un umbral que separe, con pocos errores, la H. pajonera de todas las demás clases vegetales (Figura 3.22b). Sin embargo, en el histograma se puede comprobar que los valores mínimos de la pajonera solapan los valores máximos de la retama, luego se debe esperar un mínimo error aún situando el umbral en la zona intermedia del solape. Este umbral se ha calculado como el valor promedio entre el mínimo de la H.pajonera

y el máximo de la Retama, y como se comprueba en la Tabla 3.4 el valor obtenido es coherente con lo representado en el histograma.

- Por último, la separación que ha supuesto mayor dificultad ha sido la de la Retama y el Rosalillo (Figura 3.22b). Tras realizar las pruebas pertinentes entre todos los índices que ofrecen la posibilidad de separar estas dos clases, se ha llegado a la conclusión de que, de nuevo, el índice PRI es el que mejor resuelve esta separación. Se ha umbralizado calculando el valor medio entre el primer cuartil del Rosalillo, y el tercer cuartil de la Retama. En este punto se debe tener presente que esta separación sera realizable con un mayor índice de errores que las demás, así lo demuestra el histograma de ambas clases, en el cual se aprecia el gran número de valores que hay solapados.

Tabla 3.4: Umbrales para árbol de decisión con *ROI_2*.

Se separa:	VI	Clases empleadas	Umbral
Vegetación y No vegetación	MRENDVI	Rosalillo y Veg. Muerta	0.0874915
Veg. Muerta y Suelo Desnudo	PRI	Veg.Muerta y Suelo	-0.0708105
H. Pajonera y Resto de veg.	YNDVI	H.Pajonera y Retama	0.436045
Retama y Rosalillo	PRI	Retama y Rosalillo	-0.05762

Con los índices de vegetación seleccionados y umbralizados, la creación del árbol se ha realizado haciendo uso de la herramienta *Decision Tree* disponible en el *Toolbox* de ENVI. Este procedimiento comienza haciendo uso de la herramienta *New Decision Tree*, con la cual se crea un árbol genérico en el que los nodos deben ser lo primero que se debe definir. Se caracterizarán a través del umbral calculado anteriormente y el índice con el cual operará (Figura 3.23).

En las salidas de los nodos se obtienen las clases resultantes de la operación por lo que, concatenándolos de la forma correcta, al final del proceso se obtendrá el mapa clasificado. Sin embargo, en el recorrido del árbol, se generan clases intermedias que, habitualmente, generan información de interés para el posterior análisis. En la Figura 3.23, se puede ver como el resultado de aplicar el umbral sobre el índice MRENDVI es la separación del conjunto de la vegetación y de las superficies no vegetales, luego se obtiene una clasificación intermedia que complementará la información obtenida del proceso completo y teniendo en cuenta que se pretende generar cartografía del ecosistema representado en la imagen, se considerará de gran valor para el futuro análisis de




Figura 3.22: *boxplots* e histogramas para umbralizar árbol de decisión usando ROI2.

dicha cartografía. Se justifica así la recomendación de ejecutar el proceso de clasificación en cada nodo, a medida que se vaya construyendo el árbol, pues es posible generar mapas formados por clases intermedias que aumenten cuantitativa y cualitativamente la información extraída del proceso de clasificación (Figura 3.24).

El resto de nodos que faltan para completar el árbol se obtienen de la misma forma, con sus correspondientes índices y umbrales. El árbol de decisión final y los umbrales




Figura 3.23: Definición de nodos del árbol de decisión.




Figura 3.24: Mapa clasificado de vegetación y de superficies no vegetales.

empleados se muestran en la Figura 3.25 para la ROI_2. Finalmente, queda clasificar la




Figura 3.25: Árbol de decisión generado con ROI_2.

imagen haciendo uso del árbol de decisión. Para ello, se utiliza la opción *Execute Decision Tree* del *Toolbox*. El resultado de esta operación será un mapa clasificado con las clases que componen los grupos de entrenamiento. De esa manera, han sido obtenidos los 5 mapas clasificados correspondientes a cada árbol de decisión umbralizado a partir de los datos obtenidos por grupos de entenamiento distintos.




Figura 3.26: Mapa clasificado con árbol de decisión umbralizado con *ROI_2*.

La evaluación de los mapas clasificados se ha llevado a cabo aplicando las matrices de confusión sobre cada uno, empleando, individualmente, todos los conjuntos de entrenamiento. De esta manera, se tomará como resultado final el promedio de los resultados de la matriz empleando cada conjunto de forma separada. Si bien de la matriz de confusión se pueden extraer diferentes análisis, como se ha visto anteriormente, para caracterizar la calidad de la clasificación, en este punto sólo se han evaluado los valores de precisión global y el coeficiente kappa. Estos valores para los mapas clasificados a través de los árboles de decisión se representan en las Tablas 3.5 y 3.6.

Se puede comprobar que los resultados obtenidos, a efectos cualitativos de precisión, son suficientemente altos como para considerar que los mapas han separado las distintas clases favorablemente. Para no modificar la información obtenida acerca del clasificador, los resultados anteriores han sido determinados para los mapas clasificados directamente sin haber sido implementado el postprocesado de la imagen. Las conclu-

Tabla 3.5: Resultados de *Ov. Accuracy* y *Kappa Coeff.* para árbol de decisión con *ROI_1*.

ROI	<i>Overall Acc.</i>	<i>Kappa Coeff.</i>
<i>ROI_1</i>	94,5592 %	0,9323
<i>ROI_2</i>	90,0376 %	0,8754
<i>ROI_3</i>	95,0426 %	0,9362
<i>ROI_4</i>	96,7047 %	0,9587
<i>ROI_5</i>	92,3008 %	0,9033
Promedio	93,7290 %	0,9212

Tabla 3.6: *Ov. Accuracy* y *Kappa Coeff.* para árbol de decisión con *ROI_2*.

ROI	<i>Overall Acc.</i>	<i>Kappa Coeff.</i>
<i>ROI_1</i>	92,5041 %	0,9060
<i>ROI_2</i>	90,1695 %	0,8771
<i>ROI_3</i>	95,1082 %	0,9365
<i>ROI_4</i>	93,8402 %	0,9229
<i>ROI_5</i>	91,3036 %	0,8904
Promedio	91,5851 %	0,9066

siones detalladas acerca de estos mapas clasificados y de como han sido obtenidos los resultados anteriores están detalladamente explicadas en la Sección 3.6.

En este punto finaliza el procedimiento de obtención de mapas clasificados mediante la umbralización de los distintos VIs. Se ha podido comprobar que estos son muy útiles para separar distintas clases representadas en la imagen siempre y cuando se disponga de buenos datos de entrenamiento y, como se ha visto, su aplicación es muy sencilla. Cabe destacar como conclusión, que la eficiencia de esta metodología esta fuertemente ligada a la precisión de dos factores importantes. Por un lado, los datos de entrenamiento deben ser lo suficientemente robustos para que sea posible caracterizar con ellos la mayor parte de las superficies a separar. Por otro, los umbrales deben haber sido calculados de manera que permitan la separación de cada clase sin cometer errores, de manera que no se comprometa la validez de la clasificación resultante. En el correspondiente apartado de análisis de los resultados (Sección 3.6) se realizará un estudio de las imágenes obtenidas a través de este proceso de clasificación. Además, se comprobará la validez del procedimiento en base a la comparación con los resultados de las demás metodologías de clasificación realizadas en este Trabajo.

3.5.3. Clasificación empleando imagen compuesta por VIs

Para finalizar la metodología que permitirá la generación de cartografía del PNT se ha empleado un procedimiento de clasificación basado en hacer uso combinado de los resultados obtenidos de los diferentes VI (Sección 3.4) y de los algoritmos clasificadores aplicados sobre la imagen hiperespectral que mejor resultado de precisión han dado en la Sección 3.5.1, SVM, MAHA y MAXL. En este caso, la clasificación se realizará sobre una imagen en la que cada banda que la compone será un mapa de VI diferente, así, el número de bandas totales de esta imagen variará en función del número de índices seleccionados. Con esta metodología se pretende comprobar como los VIs, combinados de la forma adecuada, permiten componer una imagen cuyas clases esten diferenciadas suficientemente como para utilizarla en un proceso de clasificación con buenos resultados de precisión. De forma gráfica, el proceso empleado para obtener los mapas clasificados a partir de esta imagen compuesta de VIs se muestra en la Figura 3.27.




Figura 3.27: Metodología de clasificación con Índices de Vegetación y clasificadores.

De esta manera, el procedimiento llevado a cabo se puede dividir en dos partes de realización secuencial:

1. Calcular la imagen con los mapas obtenidos de aplicar los VI.

2. Clasificar la imagen con los tres clasificadores mencionados y con todos los conjuntos de datos de entrenamiento disponibles, de la misma forma que en la Sección 3.5.1.

Para llevarlo a cabo, el primer paso es seleccionar los índices que van a componer la imagen a clasificar. El criterio que se ha empleado para esta selección se ha fundamentado en lo mismo que en el caso del cálculo de umbrales para los árboles de decisión (Sección 3.5.2). Se elegirán aquellos índices cuyos resultados ofrezcan una mejor separación entre clases. Es importante tener en cuenta que construir la imagen con más índices no tiene por que dar mejor resultados. Por ello es conveniente hacer una selección de los valores que se consideren suficientes para separar todas las clases. Con




Figura 3.28: Composición RGB a partir de las bandas hiperespectrales y de los índices ARVI, YNDVI y PRI.

esta selección realizada, se ha compuesto una imagen con tres índices, ARVI, YNDVI y PRI. Para crear la imagen en ENVI, se ha de emplear la herramienta *Layer Stacking*. Para ello, tras seleccionarla sólo es necesario importar los mapas de índices de vegetación que compondrán la imagen a clasificar. Así, se obtiene la imagen representada en la Figura 3.28.

Con la imagen resultante obtenida, queda aplicar cada clasificador con cada grupo de entrenamiento. El procedimiento es el mismo que se ha empleado para calcular los mapas clasificados en la Sección 3.5.1 y los algoritmos que se van a emplear en este caso son los tres que mejores resultados han dado en ese procedimiento, *Support Vector Machine*, *Mahalanobis Distance Classifier* y *Maximum Likelihood Classifier*. de

clasificar la imagen creada con tres Índices de Vegetación. Los resultados obtenidos se presentan en la Figura 3.29, donde se aprecia visualmente la similitud de las imágenes de los tres clasificadores.




Figura 3.29: Mapas clasificados a partir de imagen de VIs.

Los resultados promedio de aplicar las correspondientes matrices de confusión sobre los mapas clasificados obtenidos se muestran en la Tabla 3.7. Como se puede apreciar, se ha conseguido obtener una precisión similar a la resultante del proceso de clasificación sobre la imagen hiperespectral (115 bandas) con los mismos clasificadores y datos de entrenamiento. Cabe recordar que los resultados mostrados en la tabla son el valor promedio de los resultados obtenidos por cada uno de los conjuntos de entrenamiento para cada clasificador. A priori, esta clasificación queda validada, pues los resultados de precisión son similares a los esperados, según los resultados obtenidos por los mismos clasificadores sobre la imagen hiperespectral. Sin embargo, para asegurar la validez del procedimiento es necesario estudiar como ha sido la clasificación con cada conjunto de entrenamiento, pues el hecho de haber presentado solamente los resultados promediados de precisión no asegura que el valor resultante para cada conjunto de entrenamiento sea válido, o lo que es lo mismo, puede existir un valor de clasificación erróneo afectando al promediado, lo cual comprometería la validez del proceso. Este análisis será realizado en la Sección 3.6.

Como conclusión, esta metodología proporciona resultados adecuados, pero se requiere que los índices de vegetación hayan sido calculados correctamente y que la

Tabla 3.7: Resultados de precisión del mapa clasificado de la imagen ARVI + YNDVI + PRI.

Clasificador	<i>Ov. Accuracy</i>	<i>Kappa Coeff.</i>
SVM	94,0487 %	0,9277
MAXL	93,9076 %	0,9253
MAHA	93,0667 %	0,9124

información acerca de cómo cada índice separa las clases sea precisa, pues seleccionar los índices que compondrán la imagen con datos erróneos puede poner en riesgo la validez del proceso de clasificación. Por otro lado, el hecho de aplicar los tres clasificadores que mejor resultado han dado con anterioridad garantiza que se está trabajando con los algoritmos que mejor responden a la clasificación de la imagen original. Otro de los motivos de emplear los 5 conjuntos de entrenamiento y evaluación diferentes es garantizar la fiabilidad de los resultados presentados

3.6. Análisis de los resultados

Las tres metodologías de clasificación llevadas a cabo han dado como resultado un gran número de mapas clasificados. Visualmente los mapas obtenidos podrían considerarse válidos para un posterior análisis de la vegetación sin embargo, y como hemos visto anteriormente, los resultados de precisión obtenidos no son perfectos y, en algunos casos, son malos. La estructura de esta Sección consta de varias partes. Primero, se validan los resultados obtenidos, pues a partir de la validación se ha extraído gran parte de la información de valor añadido sobre la clasificación del entorno aparente en la imagen con ayuda de la matriz de confusión de cada mapa clasificado. Con esta herramienta se puede conocer de forma detallada cómo ha sido clasificada cada una de las clases, píxel a píxel, y a partir de ahí obtener un valor de precisión global de la clasificación. Posteriormente, se presenta el proceso de análisis llevado a cabo para obtener los resultados de cada mapa resultante, teniendo en cuenta que cada clasificador ha sido aplicado con cada conjunto de datos y que cada mapa ha sido estudiado a partir de todos los demás conjuntos. Esta cantidad de datos es la razón por la cual se tomará como resultado final el promedio de todos los mapas resultantes de un mismo clasificador. De forma separada se estudiarán los resultados obtenidos por la clasificación de la imagen compuesta por Índices de Vegetación con los clasificadores que

mejores resultados han dado sobre la imagen hiperespectral. Si bien a estos mapas se le aplicará el mismo proceso de validación que a todos los demás, se pretende realizar una comparación entre los resultados obtenidos por los clasificadores empleados al ser aplicados sobre la imagen hiperespectral y sobre la imagen compuesta de VIs. Por último, dentro del proceso de análisis de resultados se pretende justificar los motivos por los cuales han sido descartados algunos clasificadores.

Finalmente se analizará una simple operación de posprocesado que ha sido aplicada a todos los mapas clasificados resultantes, un análisis de mayorías. Con ella se ha conseguido mejorar la calidad de los resultados obtenidos de la clasificación, dando lugar a una mejor cartografía del ecosistema aparente en la imagen.

Proceso de cálculo de estadísticas de los mapas clasificados.

El proceso de cálculo de estadísticas es aplicado una vez se dispone del mapa clasificado. Está encuadrado temporalmente justo después de la clasificación y antes del posprocesado. Debido a que se dispone de multitud de imágenes clasificadas y sobre cada una se realiza el mismo procedimiento, a modo de ejemplo, para un clasificador genérico en la Figura 3.30 se representa la metodología con la cual se han obtenido los resultados finales de un clasificador.

De esta metodología cabe resaltar que para cada mapa clasificado por un algoritmo con cada conjunto de datos de entrenamiento se calculan las matrices de confusión, empleando para ello todos los demás conjuntos. Por ejemplo, el clasificador SVM genera 5 mapas clasificados con cada conjunto de datos de entrenamiento. A su vez, cada mapa será estudiado con cuatro matrices de confusión, diferenciadas por el conjunto de datos empleado como datos verídicos. Así, el mapa clasificado con *ROI_1* tendrá matrices de confusión con *ROI_2*, *ROI_3*, *ROI_4* y *ROI_5*. Los datos finales sobre este mapa clasificado serán el promedio de los resultados obtenidos por cada matriz de confusión. Repitiendo este proceso con el mapa clasificado con cada una de las *ROIs*, se tendrán 5 resultados y, volviendo a promediarlos, se obtendrá un resultado de precisión global (*Ov. Accuracy*) y coeficiente Kappa (*Kappa Coef.*) con el que quedará caracterizada la precisión con la que ha clasificado ese algoritmo.

La decisión de crear y operar con 5 conjuntos de datos de entrenamiento y evaluación (*ROIs*) para cada clasificador está basada en dos razones de diferente naturaleza. Por un

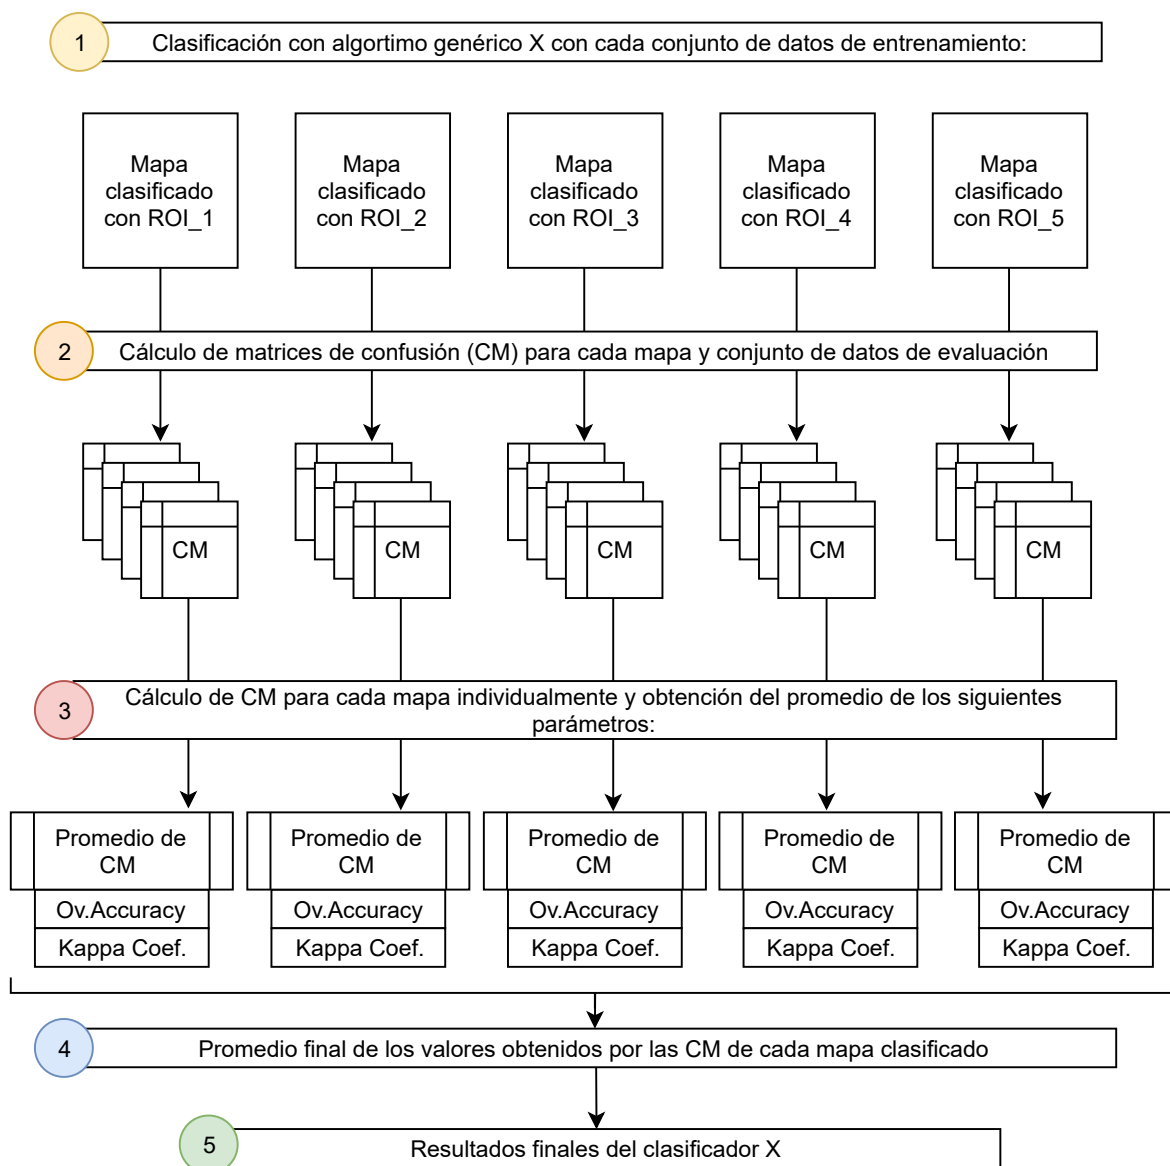


Figura 3.30: Procedimiento llevado a cabo para la obtención de estadísticas de un clasificador genérico.

lado, los defectos de preprocesado de la imagen hiperespectral provocan que píxeles de una misma superficie estén caracterizados por diferentes tonalidades, lo cual implicaría, si sólo se utilizara un conjunto de datos de entrenamiento, que dicho conjunto contuviese un gran número de píxeles. Por ello cada uno de los 5 conjuntos caracteriza píxeles distintos de las mismas superficies. Por otro lado, clasificando con cada uno de los conjuntos, se podrá caracterizar mejor el comportamiento de los clasificadores sobre imágenes del mismo entorno, en condiciones de luz similares y en la misma época del año. Si bien esto último no está considerado en título de este Trabajo, se asume que se aportará información de gran valor para el conocimiento de dicho entorno a efectos de clasificación y el empleo del procesamiento de imágenes hiperespectrales en el mismo,

a fin de estimar en mejor medida el estado de la vegetación en aplicaciones futuras. No obstante, teniendo en cuenta que por algoritmo clasificador se tienen 5 mapas clasificados, la cartografía generada es suficiente para ejecutar sobre ella un análisis que mejore el conocimiento sobre el estado del ecosistema aparente en la imagen, con lo cual también se cumple el propósito de realización de este Trabajo.

Los resultados mostrados en las tablas de secciones anteriores, así como los que se mostrarán a continuación, se obtienen promediando los valores de precisión global y coeficiente Kappa extraídos de las matrices de confusión de cada clasificador para cada conjunto de datos de entrenamiento y evaluación. Se pretende con ello disponer de un valor de precisión global basado en más de una operación de clasificación sobre la imagen con esos datos y así, proporcionar un resultado más robusto frente a posibles errores de selección de los mismos.

Como resultado del proceso de clasificación de la imagen se tiene que, como se puede apreciar en la Tabla 3.8, un valor de precisión global y coeficiente Kappa superior al 90 % en todos los clasificadores que han superado los criterios de validación. Concretamente son tres clasificadores conocidos (SVM, MAXL y MAHA) y dos algoritmos basados en árboles de decisión con índices umbralizados (DT1 y DT2). Si bien estos parámetros no detallan los diferentes errores cometidos en la clasificación de cada clase, son suficientes para determinar si los algoritmos han dado resultados aceptables de clasificación (además de la evaluación visual del mapa resultante).

Tabla 3.8: Resultados finales de la metodología de clasificación (*Ov.Accuracy* y *Kappa Coef*) para cada ROI de entrenamiento.

Classifier	ROI_1	ROI_2	ROI_3	ROI_4	ROI_5	Promedio
SVM	96,5163 %	97,4782 %	95,3536 %	94,0187 %	96,0034 %	95,8740 %
MAXL	95,5946 %	94,7293 %	93,8800 %	95,2552 %	94,1234 %	94,9167 %
MAHA	95,3215 %	94,6261 %	92,0236 %	93,0564 %	93,6163 %	93,7288 %
DT1	94,5592 %	90,0376 %	95,0426 %	96,7047 %	92,3008 %	93,7290 %

Classifier	ROI_1	ROI_2	ROI_3	ROI_4	ROI_5	Promedio
SVM	0,9562	0,9682	0,9418	0,9249	0,9489	0,9480
MAXL	0,9571	0,9335	0,9326	0,9404	0,9262	0,9380
MAHA	0,9412	0,9317	0,9233	0,9128	0,9198	0,9258
DT1	0,9299	0,8742	0,9343	0,9562	0,9343	0,9258

Es importante hacer mención al resultado del los árbol de decisión (clasificador DT1). Se sabe, gracias a las firmas espectrales (Sección 3.3), que hay dos clases de difícil separación, la retama y el rosalillo, y se ha comprobado como la umbralización que

permite la separación de estas clases sacrifica píxeles en los dos sentidos (Sección 3.5.2, Figura 3.22). Teniendo en cuenta este factor se puede concluir que aún no teniendo Índices de Vegetación que permitan la separación de todas las clases sin errores, los resultados obtenidos por los mapas de los árboles de decisión son comparables cualitativamente con los resultados obtenidos de realizar la operación con los clasificadores estadísticos. Es por ello que si se dispone de Índices de Vegetación que permitan una umbralización óptima, se pueden lograr resultados de clasificación similares a los obtenidos por los clasificadores estadísticos. Sin embargo, hay que tener en cuenta que es necesaria la selección adecuada de cada umbral para garantizar resultados válidos, lo cual es una tarea laboriosa.

Por otro lado, para evaluar los resultados obtenidos a través de la clasificación de la imagen compuesta por diferentes VIs se representan los resultados de *Ov.Accuracy* y *Kappa Coef.* obtenidos por cada clasificador estadístico empleando cada una de las *ROIs*, y se comparan con los resultados obtenidos por los mismos clasificadores aplicados a la imagen hiperespectral (Tabla 3.9).

A pesar de que los resultados de precisión global de las clasificaciones de la imagen compuesta por VI no mejoran los obtenidos de la clasificación sobre la imagen hiperespectral, es posible extraer conclusiones positivas sobre el empleo de esta técnica. Hay que tener en cuenta que únicamente se han empleado 3 bandas (VIs) en vez de 115 en el proceso de clasificación, lo que conlleva tiempos de cómputo mucho más reducidos y no requiere disponer de un elevado número de píxeles de entrenamiento, necesarios cuando se clasifica con muchas bandas. Por un lado, se ha comprobado como el resultado de clasificar una imagen en la que cada capa que la compone es un Índice de Vegetación da resultados de precisión aceptables, por otro, se deja abierto una vía que estudie como deben ser las combinaciones de estos índices para maximizar la precisión de la clasificación. No es el caso, pero se puede dar una situación en la que a priori una imagen hiperespectral no presente buenas condiciones de separación entre las clases que la componen salvo en pequeñas regiones espectrales. Es aquí donde los VI pueden ser de gran utilidad para realizar una clasificación pues, como se ha visto, es posible crear fácilmente la combinación matemática que resalte reflectividades en longitudes de onda muy concretas que ayuden a separar las clases que componen la imagen original.

Tabla 3.9: Comparación de resultados *Ov.Accuracy* y *Kappa Coef.* obtenidos de clasificar la imagen hiperspectral y la imagen compuesta por VIs.

ROI.1	Imagen dron	LS img
SVM	96,5163 %	94,6264 %
MAXL	96,5946 %	94,5042 %
MAHA	95,3215 %	93,6114 %

ROI.1	Imagen dron	LS img
SVM	0,9562	0,9322
MAXL	0,9233	0,9306
MAHA	0,9001	0,9194

ROI.2	Imagen dron	LS img
SVM	97,4782 %	93,9620 %
MAXL	94,7293 %	94,0605 %
MAHA	94,6261 %	92,4305 %

ROI.2	Imagen dron	LS img
SVM	0,9682	0,9237
MAXL	0,9335	0,9236
MAHA	0,9317	0,9046

ROI.3	Imagen dron	LS img
SVM	95,3536 %	94,4788 %
MAXL	93,8800 %	94,2751 %
MAHA	92,0236 %	93,1079 %

ROI.3	Imagen dron	LS img
SVM	0,9418	0,9305
MAXL	0,9404	0,9140
MAHA	0,9128	0,9089

ROI.4	Imagen dron	LS img
SVM	94,0187 %	93,8728 %
MAXL	95,2552 %	93,1569 %
MAHA	93,0564 %	92,7604 %

ROI.4	Imagen dron	LS img
SVM	0.9250	0,9229
MAXL	0.9404	0,9140
MAHA	0.9128	0,9089

ROI.5	Imagen dron	LS img
SVM	96,0034 %	94,3833 %
MAXL	94,1243 %	94,4549 %
MAHA	93,6163 %	93,3180 %

ROI.5	Imagen dron	LS img
SVM	0,9489	0,9293
MAXL	0,9263	0.9303
MAHA	0,9199	0,9159

Validación de los mapas clasificados.

El procedimiento llevado a cabo para determinar los resultados anteriores y los clasificadores que se han descartado se puede descomponer en dos fases realizadas de forma secuencial:

1. La validación de cada mapa clasificado a través del estudio de las matrices de confusión. Independientemente del conjunto de datos que se tome para su estudio, si no se obtienen valores de precisión global superiores al 90 % la imagen del mapa clasificado se descarta. Además visualmente se corrobora mostrando un resultado incoherente en la asignación de píxeles a cada clase. En la Figura 3.31 se aprecia como SAM no es capaz de clasificar multitud de píxeles (zonas de color negro).
2. Si bien los mapas que no cumplen la condición anterior se descartan, los valores de su matriz de confusión se almacenan puesto que se ha aplicado el mismo proceso




Figura 3.31: Imágenes de mapas clasificados con MD y SAM.

a todos los clasificadores, incluyendo los algoritmos basados en los árboles de decisión. En dos de los clasificadores en los que alguna matriz de confusión no cumple la condición anterior el valor promedio de la precisión global obtenida aplicando los diferentes conjuntos de datos de entrenamiento es inferior al 90 % (Tabla 3.10). El clasificador SID ha sido descartado a pesar de presentar buenos resultados de precisión generales puesto que el error cometido se concentra en gran medida con la asignación de las muestras de las clases *retama* y *rosalillo* y sobretodo, determina zonas de *vegetación muerta* en exceso, falseando un posible análisis de cantidad de vegetación muerta o seca. Además, visualmente se puede apreciar como presenta multitud de píxeles erróneos en prácticamente todas las zonas de vegetación (Figura 3.32).

Para reforzar el proceso de validación se han tenido en cuenta dos factores que podrían afectar a los mapas clasificados que a priori quedarían validados con las condiciones anteriores.

1. Los resultados de *Ov. Accuracy* y *Kappa coef.* obtenidos de la clasificación con cada *ROI* deben ser coherentes. Esto es, las diferentes *ROIs* están compuestas por diferentes píxeles que representan las mismas clases por lo que, si bien se considera tolerable una diferencia entre los valores obtenidos de clasificar con cada

Tabla 3.10: Resultados finales de los algoritmos de clasificación descartados:
Ov.Accuracy y *Kappa Coef.*

Clasificador	ROI_1	ROI_2	ROI_3	ROI_4	ROI_5	Promedio
SID	91,0363 %	88,4581 %	88,2172 %	88,9143 %	91,2630 %	89,5778 %
MD	79,2184 %	76,4348 %	76,5112 %	74,2386 %	76,1899 %	76,5186 %
SAM	77,5075 %	72,8326 %	76,3929 %	77,2121 %	76,7597 %	76,1410 %

Clasificador	ROI_1	ROI_2	ROI_3	ROI_4	ROI_5	Promedio
SID	0,8872	0,8388	0,8525	0,8605	0,8933	0,8665
MD	0,7384	0,7025	0,7056	0,6762	0,7002	0,7046
SAM	0,7253	0,6691	0,7129	0,7215	0,7081	0,7074




Figura 3.32: Imágenes de mapas clasificados con SID y relación de errores entre las clases *retama* y *rosalillo*.

una, cabe esperar que esa diferencia sea mínima. Dado que la imagen presenta muchas zonas de alto riesgo de error de clasificación, como multitud de píxeles de diferentes especies vegetales mezcladas o los propios defectos generados por el mosaicado de la imagen (Sección 3.2), se han considerado válidas todas aquellas clasificaciones cuya diferencia de precisión obtenida no cumple con $\pm 5\%$. Es importante tener en cuenta que las cinco clasificaciones deben ser coherentes entre sí para no descartar el clasificador aplicado con esa *ROI*.

- Una vez descartados los mapas que incumplan la condición anterior, se deben estudiar los errores resultantes en los que hayan sido, en principio, validados. En este caso se tratan de clasificar 5 tipos de superficies distintas y, como ya se ha comentado anteriormente, la matriz de confusión da, a través de los errores de omisión y comisión, el dato que representa cómo ha sido el error cometido. Analizando estos datos pueden encontrarse mapas cuyo error esté concentrado en la clasificación de los píxeles pertenecientes a dos clases con firma espectral

similar y, como se ha visto al estudiar las firmas espectrales de cada clase, la *retama* y el *rosalillo* tienden ser confundidas. Entonces, si el error cometido en una clasificación está concentrado en dos clases, el mapa debe ser descartado, pues independientemente de que la precisión global sea alta, hay clases con muchos píxeles falseados en el resultado final. La separación de las clases *retama* y *rosalillo* ha sido el motivo de descarte de algún clasificador. Como se ha visto en la Sección 3.5.2, difícilmente se han encontrado umbrales en los índices de vegetación que permitan su correcta clasificación con árboles de decisión.

Posprocesado

Como se ha comentado anteriormente, se pretende con el procedimiento llevado a cabo estudiar el comportamiento de los diferentes clasificadores empleados. Es por ello que los resultados presentados anteriormente representan los valores obtenidos directamente de la clasificación. No obstante, haciendo uso de diferentes herramientas de posprocesado es posible mejorar los resultados significativamente. En este caso ha sido aplicado un análisis de mayorías (*Majority Analysis*) con *kernels* de 3x3 y de 5x5 para tratar de corregir los píxeles espúreos que perjudican al resultado final. El resultado de aplicar este procedimiento sobre un mapa clasificado anteriormente se muestra en la Figura 3.33 (perteneciente al clasificador *DT2*) y como se puede comprobar, esta operación es capaz de corregir gran parte de los píxeles mal clasificados, lo cual es resulta muy útil porque en cierta medida se han podido solucionar los defectos de la clasificación de zonas representando varias especies vegetales entremezcladas.

Las mejoras de esta operación se vislumbran de forma general también en los resultados de *Ov. Accuracy* y *Kappa Coeff.*. Sin embargo, donde se aprecia detalladamente la mejora es en los errores de omisión o comisión, principalmente en las clases *retama* y *rosalillo*. A modo de ejemplo, en la Tabla se muestran las matrices de confusión obtenidas con los datos de referencia del conjunto *ROI_2*, para una clasificación con SVM empleando como datos de entrenamiento el conjunto *ROI_1* y para el mismo mapa posprocesado con un kernel de 5x5. Aquí se aprecia claramente la mejora producida por la operación de procesamiento. Cabe destacar que los tamaños de los *kernels* aplicados se debe ajustar al tamaño de las clases a discriminar. Por lo general el *kernel* 5x5 es el que mejor resultados da en la mayoría de imágenes clasificadas.




Figura 3.33: Imágenes resultante de la clasificación a través de árbol de decisión con *ROI_2*.

Tabla 3.11: Comparativa de las matrices de confusión para un mapa clasificado con SVM y para el mismo mapa posprocesado con un filtro de mayorías con un kernel 5x5.

SVM	Comision Error	Omision Error
Retama	2,71 %	18,10 %
Rosalillo	16,02 %	9,88 %

SVM 5x5	Comision Error	Omision Error
Retama	0,00 %	10,78 %
Rosalillo	8,91 %	6,71 %

Clasificador	Ov. Acc.	Kappa Coef.
SVM	93,0127 %	0,9219 %
SVM con kernel 5x5	96,3715 %	0,9546 %

Como conclusión general, el resultado de la clasificación ha sido cualitativamente y cuantitativamente bueno y se ha podido generar cartografía de la zona del Parque Nacional del Teide representada en la imagen hiperespectral. Además, ha resultado muy útil emplear distintas metodologías de clasificación, pues se ha comprobado que el comportamiento de algunos clasificadores estadísticos es satisfactorio al ser aplicados sobre imágenes hiperespectrales de este entorno, lo cual permitirá optimizar el proceso en análisis futuros del mismo tipo empleando metodologías de clasificación supervisada,

omitiendo el empleo desde el principio del proceso aquellos algoritmos cuyo resultado ha sido descartado. Por otro lado, las metodologías de clasificación que han empleado en su desarrollo VIs han dado como resultado mapas clasificados equiparables en calidad a los obtenidos con los algoritmos estadísticos y han tenido un desarrollo muy nutrido de información relevante. Seleccionar los umbrales de los diferentes VIs para crear los árboles de decisión implica estudiar las distribuciones del valor de los píxeles de cada clase, que resultan de la aplicación de cada índice sobre la imagen. Por lo que, además de clasificar la imagen, en este punto se ha extraído la mayor parte de información para el estudio de diferentes características vegetales. Por último, cabe resaltar el procedimiento de clasificar imágenes compuestas por VIs. El resultado de la clasificación con los algoritmos estadísticos empleados en la primera metodología (Sección 3.5.1), pero esta vez aplicados a una imagen compuesta por sólo 3 índices, ha dado un resultado de precisión a todos los efectos comparable cualitativamente con la aplicación del mismo procedimiento sobre la imagen hiperespectral. Se debe hacer mención también a la importancia de los datos de entrenamiento y evaluación a partir de los cuales se posibilita la clasificación de la imagen. La precisión con la que se seleccionan dichos datos es vital para la obtención de resultados coherentes y además, si bien la imagen presenta defectos de preprocesado que dificultan la labor del clasificador.

Para concluir, la Figura 3.34 muestra el mejor mapa clasificado de toda la metodología de clasificación con y sin posprocesado. Ha sido obtenido clasificando todas las bandas de la imagen hiperespectral con SVM empleando como datos de entrenamiento el conjunto *ROI_2*. Sin aplicar el filtro de mayorías, los resultados obtenidos (Tabla 3.8) han sido: un 97,48% de precisión global y 0,9682 de coeficiente Kappa. Con el filtro de mayorías con kernel de 5x5 los resultados han sido 99,17% de precisión global y 0,9848.




Figura 3.34: Mapa clasificado con SVM y ROI_2 con (derecha) y sin (izquierda) filtro de mayorías 5x5

Capítulo 4

Análisis del estado fenológico de la retama

4.1. Introducción

La población de retama en el Parque Nacional del Teide ha disminuido abruptamente en los últimos años. Los motivos pueden ser de distinta naturaleza, el cambio climático y el consecuente aumento de temperaturas y de periodos de sequía, la acción antropogénica a la que está sometido el entorno que habita la retama, la introducción masiva de especies foráneas herbívoras (Figura 4.1) que se alimentan de las plántulas de la misma, el cada vez más elevado riesgo de incendio, etc. Su carácter endémico le confiere una importancia que va más allá de las aplicaciones que pueda tener el contenido de sus hojas o de sus tallos. Por todos estas razones se ha realizado un estudio específico del estado de la retama, en el que a través de la aplicación de los Índices de Vegetación se puedan detectar los diferentes estados fenológicos en los que se encuentra.

La metodología empleada para realizar este estudio se describe a continuación.

4.2. Metodología y Resultados

El procedimiento llevado a cabo para extraer la información detallada de la retama consta de dos etapas fundamentales. Primero se obtiene la máscara que permitirá generar un mapa que contenga exclusivamente las zonas de retama presente en la imagen hiperespectral. Esta máscara se construye a partir del mapa que mejor haya clasifica-



Figura 4.1: Retamas y conejos.

do la clase retama del capítulo anterior. En este caso, se ha utilizado para generar la máscara el mapa clasificado con SVM a partir del conjunto de entrenamiento *ROI-1*, y posprocesado con un análisis de mayorías con un kernel de 5x5, con el fin de corregir la clase a la que pertenecen los píxeles confusos. Esta operación ha sido indispensable pues, como se ha comentado en el capítulo anterior, la retama ha sido la clase más difícil de separar de las demás, por su gran parecido espectral con el rosalillo. Para la creación de la máscara ha sido empleada la herramienta *Build Mask* de *ENVI*. Se basa en generar una imagen que contenga, únicamente, los píxeles de retama de la imagen hiperespectral que se correspondan con esa clase en el mapa SVM, de tal forma que se tenga un resultado que puede expresarse como un mapa al que se ha multiplicado por 1 cada uno de los píxeles de retama y por 0 al resto. Del producto de esta máscara con la imagen hiperespectral se obtiene el resultado que finalmente será objeto de estudio haciendo uso de los Índices de Vegetación (VI). Se han calculado todos los índices vistos en este Trabajo con el fin de analizar parámetros diferentes de la vegetación. El desarrollo de esta metodología se puede ver gráficamente en la Figura 4.2.

Para establecer los píxeles que serán evaluados por los VI es necesario crear una región de interés que contenga zonas de retama en todos sus estados, vegetación vigorosa, seca o en periodo de senescencia, con el objetivo de maximizar también los píxeles correspondientes a todos los estados en los que aparece la retama en la imagen. La aplicación de los índices se realiza exactamente igual que en el proceso llevado a cabo en el Capítulo 3, Sección 3.4, empleando la herramienta *Band Math* e introdu-




Figura 4.2: Metodología para generar información de valor para el análisis de la retama.

ciendo la expresión matemática de cada VI, así como las bandas espectrales empleadas para su cálculo. Como resultado se obtiene un mapa con los valores resultantes del índice para cada píxel de retama, del cual se extraerá el fichero estadístico para poder calcular diferentes representaciones que permitan interpretar los resultados obtenidos. Así, se tendrá material suficiente para realizar una análisis del estado de los diferentes parámetros vegetales que resultan de los Índices de Vegetación. Como resultado se presenta una composición formada por la imagen obtenida tras el cálculo de cada índice y dos representaciones que ayudan a caracterizar la información de cada uno, *boxplot* e histograma. Los valores representados en estas dos gráficas se extraen del conjunto de datos de entrenamiento creado específicamente para este procedimiento, del cual se muestran los valores de máximo, mínimo, media, mediana y desviación estándar de la distribución. Para poder realizar el análisis de la imagen de cada índice apoyándose en las gráficas de manera más sencilla, se han normalizado las distribuciones de cada uno respecto a su máximo, de manera que un 1 representa valor máximo y el valor más

cercano a 0 el mínimo. Todo el procesado de los datos obtenidos con los VI ha sido realizado con el *software Matlab*.

La presentación de los resultados pretende mostrar en conjunto toda la información que ha sido extraída de la aplicación de cada VI sobre la imagen de retama. Las imágenes resultantes de esta operación proporcionan una representación visual de los valores obtenidos para cada píxel. Además, *ENVI* proporciona estos valores de forma ordenada en forma de fichero, a partir del cual se han calculado dos tipos de gráficas que permiten darle un sentido cualitativo al contenido visual de retama aparente en el mapa. En la Figura 4.2 se representa de forma esquemática cómo se pretende aportar la información obtenida. El *boxplot* y el histograma permiten, de forma aproximada, entender qué representa cada color aparente en la imagen.

A continuación se muestra, a modo de ejemplo, el resultado del NDVI sobre el cual construir una conclusión acerca del estado de la retama, la Figuras 4 contiene de forma gráfica, la metodología llevada a cabo para presentar los resultados, así como la posibilidad de caracterizarlos de forma intuitiva:

- La imagen es el resultado visual del resultado del índice en cuestión y representa los valores de píxel de manera que los más bajos se correspondan con colores rojos y los altos con colores verdes, de acuerdo a la leyenda del lateral de la imagen. Es por ello que para la representación de todas estas imágenes se ha empleado la misma paleta de colores. Las gráficas se muestran normalizadas con respecto al máximo obtenido de la distribución del índice. De de esta manera se puede establecer una relación entre estos gráficos y la imagen resultante y, finalmente, en función de la definición del índice, realizar el análisis del estado de la retama.
- Los valores mostrados en la caja situada debajo de la imagen son extraídos directamente del cálculo del máximo, mínimo, media, mediana y desviación estándar de la distribución obtenida por el índice. De esta forma, con ayuda del *boxplot* y el histograma, es posible caracterizar cómo están distribuidos los resultados, y así, poder estimar la cantidad de vegetación que hay en los diferentes rangos de valores que pretende resaltar el índice según su definición. Por ejemplo, el índice NDVI caracteriza la vegetación verde en el rango de valores normalizados entre 0.2 y 0.8 (según su definición), luego se puede estimar que la mayor parte de los píxeles de retama, para este índice en concreto y de acuerdo a las gráficas

adjuntas y a la imagen, están comprendidos en este rango.

- El *boxplot* está representado sobre los valores de la distribución (izquierda) y sobre un eje normalizado (derecha) con respecto al valor máximo. El histograma está representado solamente sobre el eje normalizado. El objetivo de mostrar las representaciones sobre ejes normalizados se basa en poder realizar un breve análisis del resultado del índice sobre la imagen representada en este formato. Es entendible que a mayor profundidad de análisis se podrán obtener resultados con mayor precisión. No obstante, el objetivo del desarrollo de este Trabajo ha sido generar una metodología a través de la cual se pueda estimar en qué estado se encuentra la retama.

Las figuras de cada uno de los índices aplicados se adjuntan en el Anexo II. En la Figura 4.4 se muestra un trozo de cada uno de los índices calculados con el que se puede realizar una comparativa visual de los resultados.




Figura 4.3: Resultados obtenidos del estado fenológico de las retamas con NDVI.




Figura 4.4: Comparativa visual de los VI calculados para la retama.

Capítulo 5

Conclusiones

5.1. Revisión de los objetivos

Tras la realización del trabajo, se dan por cumplidos los objetivos planteados al inicio del mismo.

- Se han estudiado las principales aplicaciones de la teledetección hiperespectral de alta resolución y sus características más importantes. Así como los fundamentos de las técnicas de clasificación aplicadas en este Trabajo.
- Se ha realizado un estudio en profundidad de los principales Índices de Vegetación y sus aplicaciones, evaluando su comportamiento al ser aplicados sobre una imagen hiperespectral. Se ha profundizado en el diseño de clasificadores en árbol a partir de una selección de VIs y de los umbrales más óptimos para la clasificación. Adicionalmente, se ha podido crear un índice (*Yellowness Normalized Difference VI*) a partir del estudio de las firmas espectrales de las clases vegetales, que ha sido de utilidad para diferentes procesos de clasificación con VIs.
- Como resultado de la metodología de clasificación, se ha obtenido una gran cantidad de mapas cartográficos de la zona representada en la imagen del PNT. Además, se ha evaluado la precisión de los clasificadores empleados sobre una imagen hiperespectral de vegetación en función de los píxeles de entrenamiento y evaluación seleccionados. Con ello se tiene una idea general del comportamiento de estos clasificadores cuando son aplicados sobre imágenes de características similares.

- Por último, el estado fenológico de la retama ha sido analizado detalladamente a partir de los datos hiperespectrales. Específicamente, dado que existen índices de vegetación que resaltan diferentes propiedades de las plantas (pigmentos, contenido de agua, etc.), se han seleccionado aquellos más adecuados para ser aplicados sobre la máscara de retama y así disponer de información del estado de esta especie vegetal.

5.2. Análisis de los resultados

En el caso específico de este Trabajo se ha seleccionado una zona pequeña del Parque Nacional del Tede y, así, los tiempos de cómputo de cada procedimiento de clasificación de la imagen no han superado, en ninguno de los casos, los 2 minutos. Es por esta razón por la que se ha optado por probar diferentes técnicas de clasificación en vez de profundizar más en alguna de ellas individualmente.

La búsqueda del mejor procedimiento de clasificación, en lo que a resultados de precisión de cada una de las clases se refiere, no sólo garantiza la obtención de mapas clasificados de forma precisa con fines cartográficos, sino que además asegura que las máscaras que se obtengan a partir de estos mapas se calculen con un alto nivel de precisión.

La retama y el rosalillo no se han conseguido separar de forma óptima y multitud de píxeles de la primera (las zonas más oscuras de retama) se han clasificado, generalmente, como la segunda en los procesos de clasificación, por ello ha sido tan importante el análisis de mayorías. En las zonas en las que se mezcla la vegetación seca con retama viva (generalmente, en el centro de las retamas) se perdían algunos píxeles importantes. La vegetación de esta zona posiblemente sea la que más estresada se encuentre, teniendo en cuenta el proceso de muerte de las retamas, desde el centro de la planta hacia fuera. Ha sido posible obtener una valoración muy positiva del comportamiento de los algoritmos de clasificación aplicados sobre una imagen de estas características (visuales y espectrales).

Con los cinco conjuntos de datos de entrenamiento se ha podido estudiar cómo se comportan estos clasificadores aplicados con datos de entrenamiento de características específicas. Lo cual puede resultar muy útil para elegir qué algoritmo aplicar en futuros

trabajos de clasificación de imágenes hiperespectrales de este ecosistema.

Además, se ha podido realzar la utilidad de los Índices de Vegetación. Si bien se pueden considerar una herramienta simple de detección de estados vegetales basada en realizar operaciones algebraicas con las bandas de la imagen, ha quedado demostrado que se pueden emplear con garantías para separar clases y distinguir superficies, lo cual ha resultado de gran utilidad, pues se han obtenido resultados de clasificación tan buenos como los obtenidos con los algoritmos clasificadores aplicados sobre la imagen usando todas las bandas (115). Por un lado, la creación de árboles de decisión permite clasificar la imagen con muy buenos resultados. Es muy sencillo de implementar en ENVI si se dispone de algún mecanismo que permita obtener los umbrales. Sin embargo, sin el procesado en Matlab de los datos obtenidos hubiera sido imposible elegir los umbrales de manera precisa y, por consiguiente, clasificar con tan buenos resultados. Por otro lado, la clasificación de una imagen compuesta de VIs destaca por la precisión final obtenida.

La cadena de preprocesado tiene cierta relevancia sobre los resultados obtenidos. A pesar de que los resultados obtenidos son adecuados, los defectos del preprocesado han impedido disponer del contenido de reflectancia en bandas importantes. A efectos de clasificación puede no afectar en gran medida, pero teniendo en cuenta que en esa zona espectral (752 nm 769 nm) la vegetación refleja gran parte de la radiación que recibe, se ha considerado como una pérdida de información relativa a detectar con máxima eficiencia estados vegetales haciendo uso de los VIs.

Toda aportación al desarrollo de herramientas que permitan contribuir al seguimiento y estudio de las especies que habitan la superficie terrestre se considera positiva. Este Trabajo contiene procedimientos muy útiles para conocer diferentes formas de clasificar las clases vegetales de una imagen hiperespectral. No es posible realizar una recomendación sobre el método general a usar para estas tareas, pues los resultados son altamente dependientes de factores propios de la imagen y de los datos de entrenamiento empleados. Además, como se ha podido comprobar, con cualquiera de las metodologías empleadas se pueden obtener resultados de precisión muy altos.

5.3. Líneas futuras

Considerando que gran parte del trabajo realizado se ha basado en desarrollar diferentes metodologías de clasificación supervisada de una imagen hiperespectral, haciendo uso de diferentes herramientas, se abren distintas líneas futuras de desarrollo complementarias al trabajo que se ha ejecutado. Las que se han considerado más importantes se listan a continuación:

- Realizar un proceso similar de clasificación empleando solamente Índices de Vegetación, de forma que sea posible asignar más recursos temporales a la búsqueda de umbrales para crear árboles de decisión, y encontrar mejores combinaciones de VIs que permitan una mejor separación de clases.
- Emplear redes neuronales y *deep learning* para el proceso de clasificación. Sería de gran valor identificar las ventajas que podría aportar esta tecnología en aplicaciones de clasificación de imágenes vegetales.
- Crear, si no hay, biblioteca de estudios de monitorización a través del procesado de imágenes de alta resolución del PNT y más zonas del archipiélago canario. Estudios de estas características deben servir no sólo para comparar la evolución de cualquier ecosistema, sino también para ayudar a identificar sus causas.

Bibliografía

- [1] E. Chuvieco, *Teledeteccion ambiental : la observacion de la Tierra desde el espacio*. Ariel, 2010.
- [2] C. Cohen, “Early history of remote sensing,” in *Proceedings 29th Applied Imagery Pattern Recognition Workshop*, pp. 3–9, IEEE Comput. Soc, 2000.
- [3] D. Roberts, K. Roth, and R. Perroy, *Hyperspectral Vegetation Indices*. No. 2014299, CRC Press, 2011.
- [4] J. Marcello, Y. Padrón, J. Martín-Esquivel, D. Rodríguez, and F. Eugenia, “Evolución de la cobertura vegetal del Parque Nacional del Teide mediante Evolución de la cobertura vegetal del Parque Nacional del Teide mediante el procesado de datos de teledetección multiplataforma,” *Nuevas plataformas y sensores de teledetección. XVII Congreso de la Asociación Española de Teledetección*, no. October, pp. 263–266, 2017.
- [5] I. Visual Information Solutions, “ENVI User’s Guide Restricted Rights Notice,” 2009.
- [6] R. Pu and P. Gong, “Hyperspectral Remote Sensing of Vegetation Bioparameters,” vol. 6, pp. 101–142, 2011.
- [7] A. Lowe, N. Harrison, and A. P. French, “Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress,” *Plant Methods*, vol. 13, no. 1, pp. 1–12, 2017.
- [8] J. Kurihara, T. Ishida, and Y. Takahashi, “Unmanned Aerial Vehicle (UAV)-Based Hyperspectral Imaging System for Precision Agriculture and Forest Management,”

- in *Unmanned Aerial Vehicle: Applications in Agriculture and Environment*, pp. 25–38, Springer International Publishing, 2020.
- [9] G. Mozgeris, D. Jonikavičius, D. Jovarauskas, R. Zinkevičius, S. Petkevičius, and D. Steponavičius, “Imaging from manned ultra-light and unmanned aerial vehicles for estimating properties of spring wheat,” *Precision Agriculture*, vol. 19, pp. 876–894, oct 2018.
 - [10] F. J. Romero Ramirez, R. M. Navarro-Cerrillo, M. Á. Varo-Martínez, J. L. Quero, S. Doerr, and R. Hernández-Clemente, “Determination of forest fuels characteristics in mortality-affected Pinus forests using integrated hyperspectral and ALS data,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 68, pp. 157–167, jun 2018.
 - [11] G. Mozgeris, V. Juodkiene, D. Jonikavičius, L. Straigyte, S. Gadai, and W. Ouergemmi, “Ultra-Light aircraft-based hyperspectral and colour-infrared imaging to identify deciduous tree species in an urban environment,” *Remote Sensing*, vol. 10, oct 2018.
 - [12] T. Adão, J. Hruška, L. Pádua, J. Bessa, E. Peres, R. Morais, and J. J. Sousa, “Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry,” *Remote Sensing*, vol. 9, no. 11, 2017.
 - [13] “Hyperspectral Cameras — Hyperspectrak Imaging — Pika L.” <https://resonon.com/Pika-L>.
 - [14] “Matrice 600 (M600) - Rendimiento Sencillemente Profesional.” <https://www.dji.com/es/matrice600>.
 - [15] D. Chutia, D. K. Bhattacharyya, K. K. Sarma, R. Kalita, and S. Sudhakar, “Hyperspectral Remote Sensing Classifications: A Perspective Survey,” *Transactions in GIS*, vol. 20, pp. 463–490, aug 2016.
 - [16] U. Maulik and D. Chakraborty, “Remote Sensing Image Classification: A survey of support-vector-machine-based advanced techniques,” mar 2017.
 - [17] P. S. Sisodia, V. Tiwari, and A. Kumar, “Analysis of Supervised Maximum Likelihood Classification for remote sensing image,” in *International Conference on*

- Recent Advances and Innovations in Engineering, ICRAIE 2014*, Institute of Electrical and Electronics Engineers Inc., sep 2014.
- [18] W. Gao and Y. Peng, “Hyperspectral image classification based on multiple kernel learning with Mahalanobis distance,” *Yi Qi Yi Biao Xue Bao/Chinese Journal of Scientific Instrument*, vol. 39, pp. 250–257, mar 2018.
- [19] J. A. Richards and X. Jia, *Remote Sensing Digital Image Analysis*. Springer Berlin Heidelberg, 1999.
- [20] M. L. McHugh, “Interrater reliability: The kappa statistic,” *Biochemia Medica*, vol. 22, no. 3, pp. 276–282, 2012.
- [21] A. Bannari, D. Morin, F. Bonn, and A. R. Huete, “A review of vegetation indices,” *Remote Sensing Reviews*, vol. 13, no. 1-2, pp. 95–120, 1995.
- [22] R. Herrero, M. Cadirola, and V. K. Ingle, “Preprocessing and compression of Hyperspectral images captured onboard UAVs,” in *Unmanned/Unattended Sensors and Sensor Networks XI; and Advanced Free-Space Optical Communication Techniques and Applications*, vol. 9647, p. 964705, SPIE, oct 2015.

Parte II

Pliego de Condiciones

Pliego de Condiciones

A continuación se especifican los requisitos técnicos de este Trabajo de Fin de Grado.

Requisitos hardware

El hardware requerido queda recogido en la Tabla 5.1.

Tabla 5.1: Requisitos Hardware.

Componente	Modelo	Fabricante	Und.
Ordenador	CPU Asus GL552VW, Intel Core i7-6700HQ 2,59 GHz, 16 GB RAM	Asus	1

Requisitos software

El software requerido queda recogido en la Tabla 5.2.

Tabla 5.2: Requisitos Software.

Software	Versión	Fabricante
Sistema Operativo Windows	10 Home	Windows
ENVI	5.2	L3Harris Geospatial
Matlab	v.9.6.0.1072779 (R2019a)	Matlab

Parte III

Presupuesto

Presupuesto

Introducción

En este capítulo se estiman los gastos generados por el Trabajo Fin de Grado presentado en esta memoria. El presupuesto se divide en las siguientes partes:

- Tarifa de honorarios por tiempo empleado.
- Amortización y coste de los equipos y materiales empleados.
 - Coste del material hardware y amortizaciones.
 - Amortización del material software.
- Coste de acceso a Internet.
- Redacción de la documentación.
- Derechos de visado.
- Gastos de tramitación y envío.

Tarifa de honorarios por tiempo empleado

Este concepto contabiliza los gastos correspondientes a la mano de obra. Para realizar este cálculo, se propone la siguiente fórmula¹:

$$H = C_t \times (75 \times H_n) + C_t \times (95 \times H_e)$$

¹Según recuerda el Ministerio de Economía y Hacienda, y siguiendo directivas europeas y con aplicación al año 2011, se deben eliminar los baremos orientativos de honorarios que los colegios tradicionalmente venían publicando en sus plataformas. Es por ello que se utilizarán coeficientes estimativos de acuerdo a la condición de ingeniero técnico recién titulado.

Siendo:

- H : los honorarios totales por tiempo dedicado.
- H_n : los honorarios en jornada laboral normal.
- H_e : los honorarios fuera de la jornada laboral normal.
- C_t : el factor de corrección según el número de horas trabajadas.

Para la realización del presente Trabajo se han invertido un total de 300 horas, repartidas en jornadas de 3 horas y media durante un periodo de tres meses. Todas ellas se han realizado dentro del horario normal, por lo que el número de horas especiales no son consideradas. Además, de acuerdo a lo establecido por el COITT, el factor de corrección C_t a aplicar para 300 horas trabajadas es de 0.60, tal y como se puede comprobar en la Tabla 5.3.

Horas	Factor de Corrección, C_t
Hasta 36	1
de 36 a 72	0.90
de 72 a 108	0.80
de 108 a 144	0.70
de 144 a 188	0.65
de 188 a 360	0.60
de 360 a 510	0.55
de 510 a 720	0.50
de 720 a 1080	0.45

Tabla 5.3: Factores de corrección para el número de horas empleadas.

Finalmente, obtenemos el coste total de los honorarios, que asciende *TRECE MIL QUINIENTOS EUROS*:

$$H = 0,6 \times 75 \times 300 \text{ e} = 13.500 \text{ e} \quad (5.1)$$

Amortización y coste de los equipos y materiales empleados

Dentro de este concepto se considera tanto la amortización del hardware como del software empleado en la realización del trabajo presentado. De este modo, se estipula el

coste de amortización para un período de 3 años, utilizando un sistema de amortización lineal o constante. En este sistema, se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula haciendo uso de la siguiente fórmula:

$$C = \frac{V_{ad} - V}{N} \quad (5.2)$$

Donde:

- C: cuota de amortización anual.
- V_{ad} : valor de la adquisición.
- V: valor residual.
- N: número de años de vida útil de la adquisición.

Siendo el valor residual el valor teórico que se supone tendrá el elemento en cuestión después de su vida útil, teniendo en cuenta los índices de depreciación actual. En el caso del hardware y del software son 3 años (al 33 % de depreciación máximo por año). Sin embargo, debido a que el trabajo se ha elaborado en un periodo inferior a 3 años, que es el periodo en que se calcula la amortización de material hardware, se realizará una amortización equiparable al período de duración del mismo. Teniendo esto en cuenta, la depreciación del valor por los tres meses será del $(33 \% / 12\text{meses} \times 3\text{meses} = 8,25 \%)$. Resultando que el valor residual es $V_{\text{res}} = V_{\text{ad}} \times 0,825$. Nótese que tanto el tiempo de uso de los aparatos, como el tiempo de vida útil será $t_{\text{uso}} = 3$ meses y $t_{\text{util}} = 3$ años.

Coste del material hardware y amortizaciones.

Para las amortizaciones se utilizó la Ecuación 5.2. En la Tabla 5.4 se muestran los costes y amortizaciones del hardware.

Por lo tanto, el coste total de hardware asciende a la cantidad de *CINCUENTA Y OCHO EUROS CON TREINTA Y CUATRO EUROS*.

Tabla 5.4: Precios y costes de amortización del hardware.

Descripción	Ud	V_{ad}	V_{res}	Total
Desglose: Material de Trabajo				
CPU Asus, Intel Core i7-6700HQ 2,59 GHz, 16 GB RAM	1	1000 €	825 €	58.34 €
Total:				58.34 €

Amortización del material software

El coste total del software utilizado es la suma de las herramientas software empleadas para la realización del trabajo (Tabla 5.5). De esta manera se describe cada una de las herramientas utilizadas y el coste supuesto para su utilización usando la fórmula de amortización anteriormente citada. Por tanto, el coste total de software asciende a

Tabla 5.5: Precios y costes de amortización del software.

Descripción	V_{ad}	V_{res}	Total
ENVI v.5.1	1700 €	1402.5 €	99.2 €
Matlab v.9.6.0.1072779 (R2019a)	2000 €	1650 €	116.67 €
Total:			215.84 €

DOSCIENTOS QUINCE CON OCHENTA Y CUATRO EUROS.

Coste de acceso a Internet

Para la conexión a Internet se dispone de una solución ADSL a 10Mbps cuyo coste mensual es de 57 euros. Debido a que se ha usado dicha conexión durante cada una de las etapas de creación del mismo (3 meses), el coste de acceso a Internet se traduce a un total de *CIENTO SETENTA Y UN EUROS*.

Redacción de la documentación

Para calcular el valor monetario de la redacción del trabajo se aplicará la fórmula siguiente:

$$R = 0,07 \times P \times C_n \quad (5.3)$$

Siendo:

- R: coste de la redacción.
- P: presupuesto.
- C_n : coeficiente de ponderación en función del presupuesto

El valor de P se obtiene sumando los costes de las secciones anteriores tal y como muestra la tabla 5.6. El coeficiente de ponderación C_n para presupuestos menores de 30.050,00 € viene definido por el COITT con un valor de 1.

Tabla 5.6: Precios y costes de la ejecución del trabajo más las amortizaciones y el acceso a Internet.

Concepto	Coste
Tarifa de honorarios por tiempo empleado	13500,00 €
Costes y amortizaciones del hardware	58.34 €
Amortización del material software	215.84 €
Coste de acceso a Internet	171,00 €
Total	13945.18 €

De este modo, se obtiene que:

$$R = 0,07 \times 13\,945.18 \text{ e} = 976.16 \text{ e} \quad (5.4)$$

Al coste de redacción obtenido hasta el momento se le deben añadir otros gastos, quedando el importe final de redacción del trabajo como se detalla en la Tabla 5.7. Por lo tanto, la redacción del trabajo asciende a un total de *MIL DOCE CON DIECISEIS EUROS*.

Tabla 5.7: Coste final de redacción del trabajo.

Concepto	Coste
Redacción del trabajo	976.16 €
Papel de impresión	5,00 €
Impresión	25,00 €
Encuadernación	6,00 €
Total	1012.16 €

Derechos de visado

El COITT establece que los derechos de visado para proyectos técnicos en el año 2019 se calculan de acuerdo con la siguiente ecuación:

$$V = 0,006 \times P_1 \times C_1 + 0,003 \times P_2 \times C_2 \quad (5.5)$$

Siendo:

- **V**: coste del visado.
- P_1 : presupuesto del proyecto.
- C_1 : coeficiente reductor en función del presupuesto.
- P_2 : presupuesto de ejecución material correspondiente a la obra civil.
- C_2 : coeficiente reductor en función de P_2

El valor del coeficiente C_1 para proyectos de presupuesto inferior a 30.050,00€ es de 1. Al mismo tiempo el valor de P_2 es de 0€ ya que no se realiza ninguna obra civil. El valor del coeficiente se obtiene de la Tabla 5.8, mientras que el valor de P es el valor total del presupuesto, que se muestra en la Tabla 5.9.

Tabla 5.8: Tabla de coeficientes para el cálculo del visado.

Coste del presupuesto (€)	Factor de Correlación (C)
Hasta 30.050	1
Exceso de 30.050 hasta 60.101	0.9
Exceso de 60.101 hasta 90.151	0.8
Exceso de 90.151 hasta 120.202	0.7
...	

Tabla 5.9: Calculo total de presupuesto base para el cálculo del visado.

Concepto	Coste
Coste del tiempo empleado en la ejecución, amortización y acceso a Internet	13945.18 €
Redacción del trabajo	1012.16 €
Total	14957.34 €

Por lo tanto, el valor del visado será de:

$$V = 0,006 \times 14\,957.34 \text{ e} = 89.74 \text{ e} \quad (5.6)$$

Los costes de derechos de visado del trabajo ascienden a un total de *OCHENTA Y NUEVE CON SETENTA Y CUATRO EUROS*.

Gastos de tramitación y envío

Los gastos de tramitación y envío según la tarifa asciende a *SEIS EUROS* por cada documento visado de forma telemática.

Presupuesto antes de impuestos

Sumando todos los conceptos calculados hasta el momento, se obtiene el presupuesto, sin incluir los impuestos, que se muestra en la Tabla 5.10.

Tabla 5.10: Presupuesto total sin impuestos.

Concepto	Coste
Presupuesto base	14957.34 €
Derechos de visado	89.74 €
Gastos de tramitación y envío	6,00 €
Total	15053.08€

El presupuesto calculado, antes de incluir los impuestos, asciende a *QUINCE MIL CINCUENTA Y TRES CON OCHO EUROS*.

Presupuesto incluyendo impuestos

Al presupuesto calculado anteriormente hay que incluirle un 6.5 % de IGIC obteniendo el coste del presupuesto final (Tabla 5.11).

El presupuesto total del trabajo “Estimación del estado de salud de la vegetación en ecosistemas vulnerables mediante imágenes hiperspectrales de teledetección”, incluyendo impuestos, asciende a la cantidad de *DIECISEIS MIL TREINTA Y UNO*

Tabla 5.11: Presupuesto total.

Concepto	Coste
Total (sin IGIC)	15053.08 €
IGIC (6.5 %)	978.45 €
Total	16031.53 €

CON CINCUENTA Y TRES EUROS.

Las Palmas de Gran Canaria, a 20 de Enero de 2019

Fdo: Manuel Domínguez Calvo