

**ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y  
ELECTRÓNICA**



TRABAJO FIN DE GRADO

**Generación de Cartografía del Fondo Costero  
Mediante Imágenes Multiplataforma de Alta Resolución.**

**Titulación:** Grado en Ingeniería en Tecnologías de la Telecomunicación

**Mención:** Sistemas de Telecomunicación

**Autor:** Álvaro Mesa Suárez

**Tutores:** Javier Marcello Ruiz

Francisco Eugenio González

**Fecha:** Junio 2019



**ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y  
ELECTRÓNICA**



TRABAJO FIN DE GRADO

**Generación de Cartografía del Fondo Costero  
Mediante Imágenes Multiplataforma de Alta Resolución.**

**HOJA DE EVALUACIÓN**

Calificación: \_\_\_\_\_

**Presidente**

Fdo.: \_\_\_\_\_

**Vocal**

**Secretario**

Fdo.: \_\_\_\_\_

Fdo.: \_\_\_\_\_

**Fecha:** Junio 2019

---



# Resumen

En este Trabajo de Fin de Grado se aborda el uso de la teledetección para obtener información de utilidad para la monitorización del medioambiente. Para ello, se propone realizar un seguimiento de la vegetación subacuática, mediante multiplataformas de teledetección, que nos permita captar diferentes tipos de información en el área de estudio.

En este contexto se ha hecho un estudio del fondo costero de la zona del Parque Nacional de Cabrera (Islas Baleares), utilizándose una imagen multiespectral de muy alta resolución captada por el satélite WorldView-2, que abarca la totalidad del archipiélago de Cabrera, y otra hiperespectral, registrada por un dron, en una zona específica de la isla predominante. Mediante la aplicación de diferentes técnicas de pre-procesado y algoritmos de clasificación se han obtenido resultados interesantes, observables en los mapas de cartografía del fondo marino generados.

Además, aprovechando la cadencia temporal entre ambas imágenes, se aplicaron técnicas de detección de cambios que permitieron conocer la variabilidad del comportamiento del fondo costero, a bajas profundidades, en una de las bahías del ecosistema natural bajo estudio, entre 2016 y 2018.

En resumen, la ejecución de este Trabajo Fin de Grado no solo ha permitido identificar la variedad subacuática del Parque Nacional mediante sensores multiespectrales e hiperespectrales a bordo de satélite y dron, respectivamente, sino que, adicionalmente, obtener resultados cuantitativos y cualitativos de su variación multitemporal.

Palabras clave: multiplataforma; imagen multiespectral de muy alta resolución; imagen hiperespectral; cartografía marina; variedad subacuática; detección de cambios.



# Abstract

This dissertation addresses the use of remote sensing in order to obtain useful information for the conservation of the environment. In this context, we propose to monitor underwater vegetation through multiple platforms, which allow us to capture the different types of information in the study area.

In this work, we have done a study on the seafloor area of the Cabrera National Park, in the Balearic Islands. To do this, we used a very high resolution multispectral image captured by the WorldView-2 satellite, which covers the entire Cabrera archipelago, and a hyperspectral one recorded by a drone, in a specific area of the predominant island. Through the use of different pre-processing techniques and classification algorithms, interesting results have been obtained, observable in the seabed maps generated. Also, taking advantage of the time lag between the images collected, we were able to apply change detection techniques to monitor the behavior of the coastal bottom in one of the bays of the National Park between 2016 and 2018.

Finally, we were able to obtain very satisfactory results in the subsequent analysis carried out on the maps generated from the images of the different platforms, demonstrating their usefulness as a tool to know in detail the coastal bottom in shallow waters. In summary, we not only identified the underwater variety of the National Park, but also, of equal importance, an approximate idea of how vegetation changes in time.

Keywords: multiplatform; very high resolution multispectral image; hyperspectral image; marine cartography; underwater variety; change detection.



# Índice

<b>MEMORIA .....</b>	<b>1</b>
<b>CAPÍTULO 1. INTRODUCCIÓN .....</b>	<b>3</b>
1.1. ANTECEDENTES .....	5
1.2. OBJETIVOS .....	7
1.3. ESTRUCTURA DE LA MEMORIA .....	7
<b>CAPÍTULO 2. SISTEMAS DE TELEDETECCIÓN.....</b>	<b>9</b>
2.1. FUNDAMENTOS DE LA TELEDETECCIÓN.....	11
2.1.1. <i>Espectro electromagnético</i> .....	11
2.1.2. <i>Tipos de sensores</i> .....	13
2.1.3. <i>Resolución de un sistema sensor</i> .....	13
2.2. SATÉLITE WORLDVIEW-2 .....	15
2.3. DRON DJI MATRICE 600 .....	17
2.3.1. <i>Cámara hiperspectral Pika-L</i> .....	18
<b>CAPÍTULO 3. TÉCNICAS DE PROCESADO.....</b>	<b>21</b>
3.1. CORRECCIÓN GEOMÉTRICA .....	23
3.2. CORRECCIÓN RADIOMÉTRICA .....	23
3.2.1 <i>Cálculo de reflectividades</i> .....	24
3.3. CORRECCIÓN ATMOSFÉRICA .....	24
3.4. ENMASCARAMIENTO .....	25
3.5. CLASIFICACIÓN DIGITAL .....	25
3.5.1. <i>Fases de entrenamiento</i> .....	26
3.5.2. <i>Fase de asignación</i> .....	27
3.5.2. <i>Fase de Verificación</i> .....	30
<b>CAPÍTULO 4. GENERACIÓN DEL MAPA DEL FONDO COSTERO MEDIANTE IMAGEN SATÉLITE .....</b>	<b>31</b>
4.1. DATOS.....	33
4.2. CALIBRACIÓN RADIOMÉTRICA.....	35
4.3. CORRECCIÓN ATMOSFÉRICA .....	36
4.4. ENMASCARAMIENTO .....	39
4.4.1 <i>Máscara de profundidad</i> .....	39
4.4.2. <i>Máscara de tierra, nubes y barcos</i> .....	40
4.5. CLASIFICACIÓN .....	42
4.5.1. <i>ROIs de Entrenamiento</i> .....	42
4.5.2. <i>ROIs de evaluación</i> .....	47
4.5.3. <i>Separabilidad entre clases y firmas espectrales</i> .....	47
4.5.4. <i>Análisis a nivel de algoritmo de clasificación</i> .....	49
4.5.5. <i>Análisis a nivel de clases</i> .....	52
4.5.6. <i>Cartografía del fondo costero del Parque Nacional de Cabrera</i> .....	53
<b>CAPÍTULO 5. GENERACIÓN DEL MAPA DEL FONDO COSTERO MEDIANTE IMAGEN DRON .....</b>	<b>55</b>
5.1. DATOS.....	57
5.2. PREPROCESADOS DRON .....	58
5.2.1. <i>Procesado radiométrico y uso de batimetría de alta resolución</i> .....	58
5.2.2. <i>Procesado Geométrico, corrección de hipercubos y mosaicado</i> .....	58
5.2.3. <i>Enmascaramiento</i> .....	59
5.3. CLASIFICACIÓN .....	60
5.3.1 <i>ROIs de entrenamiento y evaluación</i> .....	60
5.3.2. <i>Separabilidad entre clases y firmas espectrales</i> .....	61

5.3.3. Análisis a nivel de clasificación.....	62
5.3.4. Análisis a nivel de clases.....	65
5.3.5. Cartografía del fondo costero de la zona del Puerto en el Parque Nacional de Cabrera ...	65
<b>CAPÍTULO 6. GENERACIÓN DEL MAPA DE CAMBIOS A PARTIR DE IMÁGENES MULTITEMPORALES</b>	<b>67</b>
6.1. COMPARATIVA Y DETECCIÓN DE CAMBIOS.....	69
<b>CAPÍTULO 7. CONCLUSIONES Y LÍNEAS FUTURAS .....</b>	<b>73</b>
7.1. REVISIÓN DE LOS OBJETIVOS.....	75
7.2. ANÁLISIS DE RESULTADOS.....	75
7.3. LÍNEAS FUTURAS.....	76
<b>CAPÍTULO 8. BIBLIOGRAFÍA .....</b>	<b>77</b>
BIBLIOGRAFÍA .....	79
<b>PLIEGO DE CONDICIONES .....</b>	<b>83</b>
PC.1. REQUISITOS HARDWARE.....	85
PC.2. REQUISITOS SOFTWARE.....	85
PC.3. IMÁGENES UTILIZADAS.....	85
<b>PRESUPUESTO .....</b>	<b>87</b>
P.1. RECURSOS MATERIALES.....	89
P.2. TRABAJO TARIFADO POR TIEMPO EMPLEADO .....	90
P.3. COSTES DE REDACCIÓN DEL TFG .....	91
P.4. MATERIAL FUNGIBLE .....	92
P.5. DERECHOS DE VISADO DEL COITT .....	93
P.6. GASTOS DE TRAMITACIÓN Y ENVÍO .....	93
P.7. APLICACIÓN DE IMPUESTOS .....	93

## Índice de Figuras

Figura 1.1. (a) Archipiélago Balear y (b) archipiélago de Cabrera.....	5
Figura 1.2. Posidonia Oceánica salvaje.....	5
Figura 1.3. Modelo de prospección de Sonar de Barrido Lateral.....	6
Figura 2.1. Espectro Electromagnético.....	11
Figura 2.2. Firma espectral de diferentes cubiertas.....	12
Figura 2.3. Penetración del agua en función de la longitud de onda.....	12
Figura 2.4. Tipos de radiación incidente en un sensor de teledetección.....	13
Figura 2.5. Resolución espacial de diferentes satélites. (a) QUICKBIRD 2007 (1m), (b) IKONOS 2007 (4m), (c) LANDSAT etm857_03 (28m). Figura 2.6. Tipos de resolución espectral.....	14
Figura 2.6. Tipos de resolución espectral .....	14
Figura 2.7. Resolución espacial/espectral de diferentes sensores de teledetección.....	15
Figura 2.8. Modelo satélite WorldView-2.....	16
Figura 2.9. Bandas espectrales del WV2.....	17
Figura 2.10. Plataforma DJI Matrice 600 durante la captación de imágenes en Cabrera.....	18
Figura 2.11. Bandas utilizadas por los modelos Pika.....	19
Figura 3.1. Calibración de reflectividad y radiancia.....	23
Figura 3.2. Efectos atmosféricos sobre el cálculo de la reflectividad.....	24
Figura 3.3. Fundamentos de la clasificación digital.....	25
Figura 3.4. Relaciones entre clases y nivel espectral.....	26
Figura 3.5. Concepto de método de máxima probabilidad.....	27
Figura 3.6. Representación del ángulo de similitud entre dos vectores espectrales.....	28
Figura 3.7. representación hiperplano separador de dos clases bien distinguidas.....	28
Figura 3.8. Nube de datos superpuestas.....	29
Figura 3.9. Diferentes soluciones de hiperplano frente a datos superpuestos.....	29
Figura 4.1. Imagen del PN Cabrera captada por el satélite WV2.....	33
Figura 4.2. Software online para la obtención del AOT.....	37
Figura 4.3. Parámetros establecidos para el ajuste FLAASH.....	38
Figura 4.4. Imagen de estudio con las correcciones y calibraciones aplicadas.....	39
Figura 4.5. Imagen enmascarada a 40 metros de profundidad.....	40
Figura 4.6. Banda 7 de la imagen WV2.....	41

Figura 4.7. Histograma de la banda 7 de la imagen WV2.....	41
Figura 4.8. Resultado de aplicar las máscaras con isobata de 40 metros definida. (a) imagen completa y (b) zona del Port.....	42
Figura 4.9. Cartografía marina del Parque Nacional Cabrera generada por el Instituto Nacional de Oceanografía.....	43
Figura 4.10. Cartografía marina del Parque Nacional Cabrera generada por el Proyecto LIFE Posidonia.....	44
Figura 4.11. Elementos subacuáticos que constituyen el fondo marino del PN Cabrera: (a) Rocas Infralitorales y Circalitorales, (b) Arena y Fondo Detrítico, (c) Posidonia y (d) Cymodocea.....	45
Figura 4.12. Muestra ejemplo de las Regiones de Interés escogidas para cada clase: (a) Clase Rocas Infralitorales y Circalitorales, (b) clase Arena y Fondo Detrítico, (c) clase Posidonia y (d) clase Cymodocea.....	46
Figura 4.13. Índices de separabilidad entre clases.....	48
Figura 4.14. Firmas espectrales de cada clase.....	48
Figura 4.15. Resultados de la clasificación: (a) Maximun Likelihood. (b) Spectral Angle Mapper (c) Support Vector Machine.....	50
Figura 4.16. Comparativa de la cartografía en la zona del Puerto entre: (a) mapa IDEO (2011) [22], (b) mapa ML, (c) mapa SAM y (d) mapa SVM.....	51
Figura 4.17. Comparativa de la cartografía en la zona de La Olla entre: (a) mapa IDEO (2011) [22], (b) mapa ML, (c) mapa SAM y (d) mapa SVM.....	51
Figura 4.18. Comparativa de imágenes del PN Cabrera: (a) Imagen procedente del WV2 y (b) cartografía temática.....	53
Figura 4.19. Cartografía marina PN Cabrera: (a) Zona del Port (Puerto) y (b) zona de la Olla.....	54
Figura 5.1. (a) Superficie de interés para el estudio mediante dron e (b) imagen de la zona el día de la captación.....	57
Figura 5.2. Imagen dron en color natural.....	58
Figura 5.3. Imagen dron tras preprocesarla.....	59
Figura 5.4. Índice de separabilidad entre clases para las ROIs de entrenamiento.....	61
Figura 5.5. Firmas espectrales media de cada clase para las ROIs de entrenamiento.....	62
Figura 5.6. Nivel de información por bandas tras PCA.....	63
Figura 5.7. (a) Cartografía del IDEO [22] y resultados de la clasificación: (b) SVM a primeras 20 bandas tras PCA, (c) SVM a primeras 40 bandas, (d) SVM a las 150 bandas.....	64
Figura 5.8. Comparativa de imágenes: (a) Imagen dron de una zona del Puerto en el PN Cabrera y (b) cartografía temática.....	66

Figura 6.1. Imágenes de la zona Puerto, PN Cabrera: (a) Septiembre 2016 (WV2) y (b) septiembre 2018 (dron), con sus cartografías marina: (c) Septiembre 2016 (WV2) y (d) septiembre 2018 (dron).....69

Figura 6.2. Mapa de cambios del fondo marino en la zona Puerto del PN Cabrera ente septiembre de 2016 y septiembre de 2018.....70

## Índice de tablas

Tabla 3.1. Ejemplo de matriz de confusión.....	30
Tabla 4.1. Información de los metadatos de la imagen en cuestión.....	34
Tabla 4.2. Gama de productos para WV2.....	35
Tabla 4.3. Información espectral de la imagen obtenida.....	35
Tabla 4.4. Tabla de clases por colores asignados a la clasificación de la cartografía marina.....	44
Tabla 4.5. Número de ROIs de entrenamiento por clases.....	46
Tabla 4.6. Número de ROIs de evaluación por clases.....	47
Tabla 4.7. Fiabilidad y coeficiente kappa de cada clasificador empleado.....	49
Tabla 4.8. Matriz de confusión para el clasificador ML .....	52
Tabla 4.9. Matriz de confusión para el clasificador SAM.....	52
Tabla 4.10. Matriz de confusión para el clasificador SVM.....	52
Tabla 4.11. Inventario de la ocupación del fondo marino en el PN Cabrera.....	54
Tabla 5.1. Tabla de clases por colores asignados a la clasificación de la cartografía marina para la imagen dron.....	60
Tabla 5.2. Número de ROIs de entrenamiento por clases para la imagen dron.....	61
Tabla 5.3. Número de ROIs de evaluación por clases para la imagen dron.....	61
Tabla 5.4. Fiabilidad y coeficiente kappa del SVM en cada caso.....	63
Tabla 5.5. Matriz de confusión para el clasificador SVM en la imagen PCA de 20 bandas.....	65
Tabla 5.6. Matriz de confusión para el clasificador SVM aplicado sobre las primeras 40 bandas..	65
Tabla 5.7. Matriz de confusión para el clasificador SVM aplicado sobre las 150 bandas.....	65
Tabla 5.8. Inventario de la ocupación del fondo marino en la zona Puerto del PN Cabrera.....	66
Tabla 6.1. Leyenda significativa en la detección de cambios.....	71
Tabla 6.2. Comparativa de la ocupación de cada categoría en las dos fechas.....	71
Tabla P.1 Cálculo del coste de recursos hardware.....	89
Tabla P.2 Cálculo del coste de recursos software.....	90
Tabla P.3 Cálculo del coste de imágenes.. ..	90
Tabla P.4 Factor de corrección en función del número de horas invertidas.....	91
Tabla P.5 Presupuesto (recursos materiales y tiempo empleado).....	92
Tabla P.6 Costes del material fungible.....	92
Tabla P.7 Costes totales del TFG.....	93



# MEMORIA



---

# Capítulo 1

## **INTRODUCCIÓN**

---



## 1.1. Antecedentes

El Archipiélago de Cabrera es, desde 1991, de interés general para España debido al elevado valor natural y cultural, la gran representatividad de su sistema natural, su amplia superficie, suficiente para permitir la evolución normal de los procesos ecológicos, la escasa intervención humana y no tener núcleos urbanos habitados en su interior. Por estos motivos se le otorgó la clasificación de Parque Nacional.

Este enclave se encuentra situado al sur de la isla de Mallorca, y comprende el Archipiélago de Cabrera propiamente dicho, formado por las 19 islas e islotes, y su entorno marino, con una extensión total de 10.021 hectáreas, de las cuales 8.073 son marinas [1].

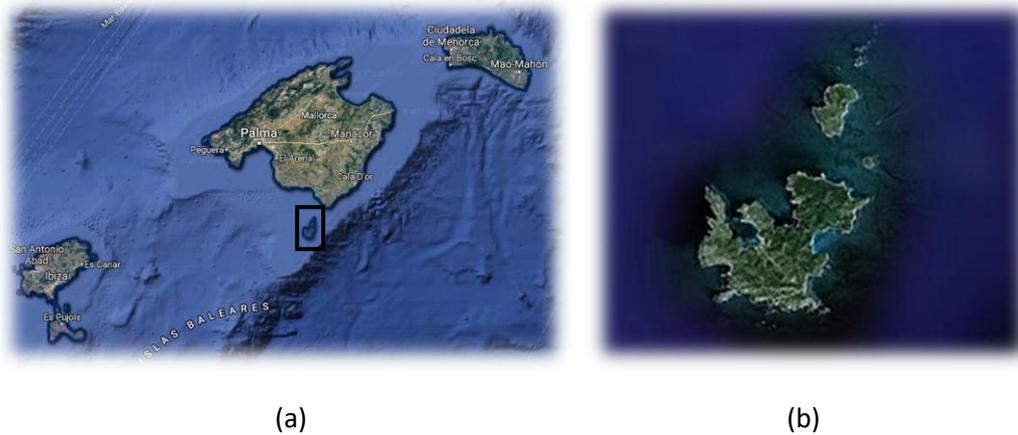


Figura 1.1. (a) Archipiélago Balear y (b) archipiélago de Cabrera. (Fuente: [https://es.wikipedia.org/wiki/Parque\\_nacional\\_mar%C3%ADtimo-terrestre\\_del\\_Archipi%C3%A9lago\\_de\\_Cabrera](https://es.wikipedia.org/wiki/Parque_nacional_mar%C3%ADtimo-terrestre_del_Archipi%C3%A9lago_de_Cabrera))

Las praderas de posidonia (Figura 1.2.) son la principal comunidad del litoral mediterráneo a preservar en sus aguas debido a sus altos niveles de productividad, elevada biodiversidad e importancia en la protección y estabilidad de la línea de costa. En este sentido, las praderas constituyen un ecosistema maduro, dada su capacidad para modificar las condiciones ambientales de los lugares en los que se afianza: atrapando el sedimento y contribuyendo, así, a la limpieza del agua, oxigenando las aguas durante el otoño, el invierno y sobre todo en primavera, atrayendo numerosas especies animales y vegetales que constituirán la comunidad posidonícola [2].



Figura 1.2. Posidonia Oceánica salvaje. (Fuente: <https://posidoniacosmetics.es/usos-tradicionales-y-propiedades-de-la-posidonia-oceanica/>)

Lamentablemente, dichos servicios naturales se ven amenazados por continuas agresiones humanas, tales como la contaminación del agua del mar. Donde gran parte de los residuos fruto de la actividad humana acaban de forma directa o indirecta en el mar, y pueden producir diferentes impactos sobre las praderas de posidonia. Las botellas vacías, los plásticos o la chatarra ensucian el fondo. Los sedimentos procedentes del litoral (emisarios, vertidos, etc.) aumentan la turbidez del agua disminuyendo la cantidad de luz aprovechable por la planta. Las aguas residuales y los fertilizantes provocan el aumento de los niveles de nutrientes y de materia orgánica, la oxidación de la cual reduce la cantidad de oxígeno disuelto en el agua, lo cual puede tener graves consecuencias sobre las praderas. Por otro lado el ejercicio de la pesca de arrastre con barcas de arrastre y similares sobre la pradera, actividad ilegal en la práctica, o el fondeo de embarcaciones, produce la apertura de claros en las praderas, debido al arranque de gran cantidad de fajos, incluso de matas enteras. También aumenta la turbidez del agua, al volver a suspender los sedimentos, disminuyendo así la cantidad de luz que llega a la planta. Y, por último, muchas actividades que se llevan a cabo en el litoral, como los dragados para la construcción de puertos y espigones, la extracción y vertido de arena, fangos, etc., aumentan la cantidad de partículas en suspensión que cuando se depositan en el fondo pueden tapar las plantas de posidonia. En otros casos, los dragados pueden dejar al descubierto las raíces de las matas de posidonia que quedan expuestas al oleaje y pueden así romperse con facilidad [2].

Con el objetivo de realizar este seguimiento, para la obtención de la cartografía bionómica y, en especial, la posidonia, históricamente se ha utilizado la técnica de cartografiado de Sonar de Barrido Lateral, como se muestra en la Figura 1.3. Además, se completa esta técnica de cartografiado con filmaciones mediante vídeo remolcado o ROV. Aparte, para el posicionamiento del registro de fondo se utiliza un GPS-Diferencial que ofrece la posición cada segundo.

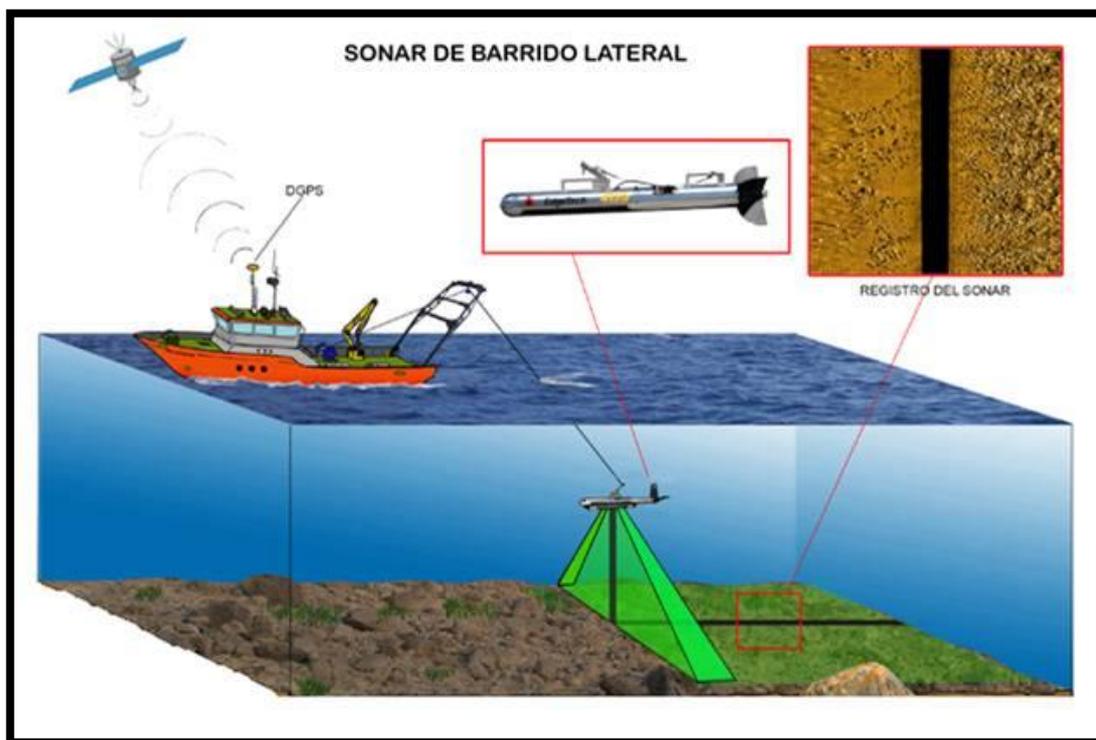


Figura 1.3. Modelo de prospección de Sonar de Barrido Lateral. (Fuente: <http://cimacanarias.com/index.php/blog-noticias/271-blog9-cartografia>)

Sin embargo, para llegar a caracterizar la pradera de Posidonia Oceánica en el archipiélago de Cabrera se necesitarán multitud de estaciones de seguimiento equipadas con dicha tecnología de captación [1]. En este contexto, la teledetección puede ser una tecnología útil, más rápida y económica para la caracterización del fondo costero en zonas poco profundas.

## 1.2. Objetivos

A través de este Trabajo de Fin de Grado, se estudiará el fondo marino en las zonas costeras de aguas poco profundas pertenecientes al Parque Nacional Cabrera, en las Islas Baleares. El objetivo fundamental será generar la cartografía del fondo costero mediante imágenes multiplataforma de alta resolución. Para ello se contó con una imagen multispectral de muy alta resolución espacial captada por el satélite WorldView-2 durante el mes de septiembre de 2016 y otra hiperespectral registrada por un dron también en septiembre, pero de 2018. Ambas imágenes, además, permitirán generar un mapa de cambios entre las dos fechas y comparar las ventajas que nos puede llegar a proporcionar cada una de las dos tecnologías de captación de imágenes de alta resolución. En este contexto, los objetivos específicos son los siguientes:

1. Estudio de las principales características de las tecnologías multispectral e hiperespectral.
2. Estudio de las técnicas de preprocesado y clasificación aplicadas a cada una de las imágenes.
3. Generación de cartografía de fondo costero mediante imagen multispectral de satélite.
4. Generación de cartografía de fondo costero mediante imagen hiperespectral de dron.
5. Generación de mapa de cambios en el fondo costero.
6. Análisis de las diferencias entre ambas tecnologías.

## 1.3. Estructura de la memoria

El presente documento está compuesto por tres partes diferenciadas en las que se abordará la totalidad del trabajo realizado. Estos apartados son: Memoria, Pliego de condiciones y Presupuesto. A su vez, el apartado Memoria está formado por 7 capítulos que se detallan a continuación:

- Capítulo 1: Introducción.

Este primer capítulo contextualiza el Trabajo Fin de Grado, especificando los objetivos abordados y el contenido del documento.

- Capítulo 2: Sistemas de Teledetección.

En este capítulo se estudian los fundamentos de la teledetección, así como las diferentes plataformas y tecnologías que se darán uso en este trabajo.

- Capítulo 3: Técnicas de Procesado.

Este apartado corresponde al análisis y procedimiento de la etapa del procesado de la imagen. Se definen las técnicas necesarias que se necesitan aplicar a las imágenes de unas características concretas y sus posteriores procesos de clasificación para la generación de mapas temáticos.

- Capítulo 4: Generación del Mapa del Fondo Costero Mediante Imagen de Satélite.

El objetivo de este capítulo será aplicar las técnicas anteriores sobre la imagen procedente del satélite WorldView-2 con el fin de estudiar los resultados y conseguir un mapa del fondo costero lo más preciso posible.

- Capítulo 5: Generación del Mapa del Fondo Costero Mediante Imagen Dron.

Una vez obtenida la cartografía completa mediante imagen de satélite, se hará el mismo estudio para una imagen dron en un área más reducida gracias a la aportación de la información captada por la cámara Pika-L a bordo del dron DJI Matrice 600.

- Capítulo 6: Generación del Mapa de Cambios.

En el capítulo 6, se tomarán las dos cartografías procedentes de años distintos para analizar los cambios en la vegetación subacuática de la zona.

- Capítulo 7: Conclusiones y Líneas Futuras.

Finalmente, se detallan las conclusiones del Trabajo Fin de Grado y se hace una revisión de los objetivos, así como se presentan posibles guías para futuras investigaciones.

- Capítulo 8: Bibliografía.

Capítulo final en el que se referencian artículos, libros y documentación.

---

# Capítulo 2

## **SISTEMAS DE TELEDETECCIÓN**

---



## 2.1. Fundamentos de la Teledetección

La teledetección es la obtención de información sobre un objeto, área o fenómeno a través del análisis de datos obtenidos por un dispositivo que no se encuentra en contacto directo con el elemento bajo estudio.

### 2.1.1. Espectro electromagnético

Anteriormente se definió la teledetección como aquella técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible, es preciso que entre los objetos y el sensor exista algún tipo de interacción. Este proceso implica tres elementos obvios en cualquier sistema de teledetección: sensor, objeto observado y flujo energético que pone en relación al sensor del objeto.

Respecto al último elemento, sabemos que se puede definir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. En función de esto, se suelen establecer una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. Dicha organización se denomina Espectro Electromagnético (Figura 2.1) [3].

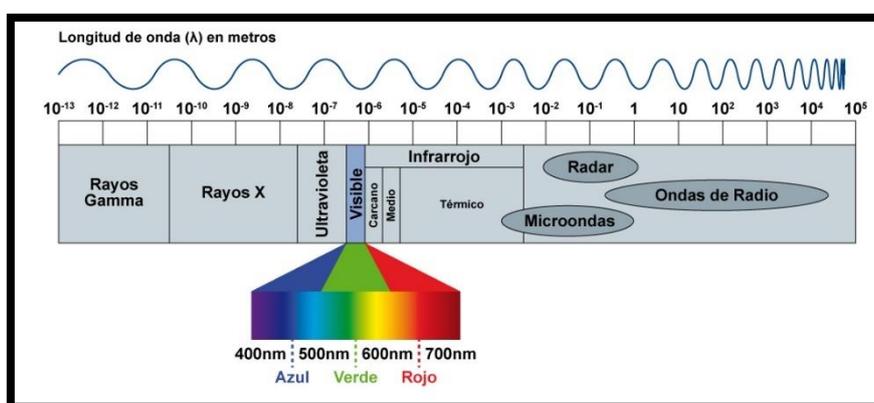


Figura 2.1. Espectro Electromagnético. (Fuente: <http://centroderecursos.educarchile.cl/handle/20.500.12246/40847>)

Desde el punto de vista de la teledetección, conviene destacar una serie de bandas espectrales, que son las más frecuentes empleadas con la tecnología actual.

- Espectro visible (0.4 a 0.7  $\mu\text{m}$ )
- Infrarrojo cercano (0.7 a 1.3  $\mu\text{m}$ )
- Infrarrojo medio (1.3 a 8  $\mu\text{m}$ )
- Infrarrojo lejano o térmico (8 a 14  $\mu\text{m}$ )
- Microondas (a partir de 1 mm)

Una vez definida la energía electromagnética encargada de transportar la información del objeto al sensor, uno de los principios de la teledetección es el tipo de interacción que ésta tiene con los elementos: absorción, transmisión y reflexión. Dependiendo de las propiedades químicas, físicas y biológicas de cada elemento y la longitud de onda de la energía electromagnética que recibe, varía la proporción de energía que es reflejada, denominada Firma Espectral, y es posteriormente captada por el sensor [3].

Para poder caracterizar una determinada cubierta, es importante conocer su comportamiento a diversas longitudes de onda (Figura 2.2.), ya que esto permitirá determinar mejor sus diferencias con respecto a cubiertas similares.

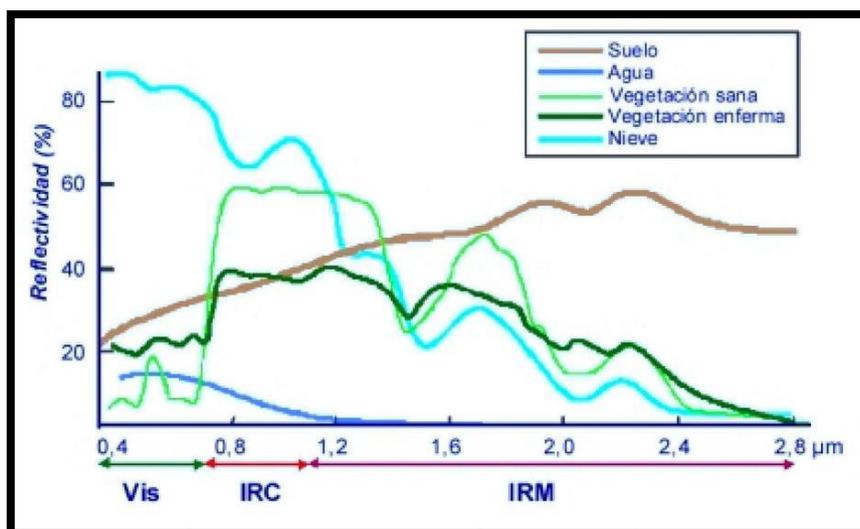


Figura 2.2. Firma espectral de diferentes cubiertas. (Fuente:

<https://docplayer.es/12754733-Landsat-realizado-por-garcia-varela-alvaro.html>)

Como se puede observar, algunas cubiertas tienden a presentar una respuesta uniforme en distintas longitudes de onda, mientras que otras ofrecen un comportamiento mucho más selectivo. La nieve refleja la mayor parte de la energía incidente a distintas longitudes de onda, por lo que presenta una reflectividad alta. Por el contrario, el agua absorbe mayor parte de la energía que recibe, presentando una reflectividad máxima en el azul. Por su parte, la vegetación presenta bajos valores de reflectividad en el espectro visible, más elevados en el infrarrojo cercano y menores en el medio. Es importante considerar que la energía captada por el sensor no sólo depende de la reflectividad de la cubierta, sino también de factores externos, por ejemplo, las condiciones atmosféricas y la geometría de observación.

Por otro lado, en el contexto de este Trabajo Fin de Grado, al detectar cubiertas localizadas debajo del agua, la firma espectral variará en función de la profundidad (ver Figura 2.3).

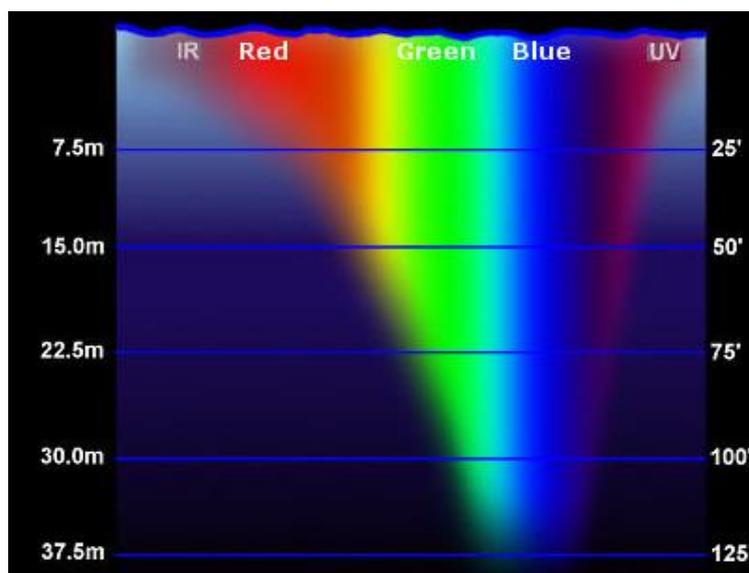


Figura 2.3. Penetración del agua en función de la longitud de onda.

### 2.1.2. Tipos de sensores

Como ya se indicó anteriormente, un sistema de teledetección requiere, al menos, tres componentes: fuente de energía, superficie terrestre y sensor. Ahora se abordará las características de este último.

Entre las variadas formas de clasificar los sensores remotos, una de las más habituales considera su procedimiento de recibir la energía procedente de las distintas cubiertas. En este sentido, se habla de dos tipos de sensores: pasivos, cuando se limitan a recibir la energía proveniente de un foco exterior a ellos, y activos, cuando son capaces de emitir su propio haz de energía.

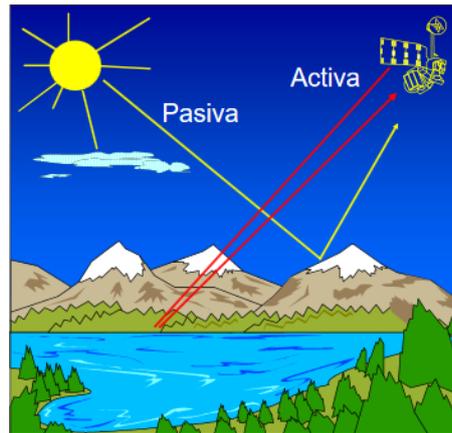


Figura 2.4. Tipos radiación incidente en un sensor de teledetección.

Entre los sensores pasivos hay una subclasificación que considera el procedimiento para grabar la energía recibida. De acuerdo a ello, puede hablarse de sensores fotográficos, óptico-electrónicos y de antena [3]. Los primeros resultan muy familiares, puesto que se basan en las mismas técnicas aplicadas en la fotografía convencional, pero los que nos concierne a nosotros son los segundos. Ya que se trata del tipo de sensor con el que está equipado el satélite WorldView-2 y el dron con el que se han obtenido nuestras imágenes.

### 2.1.3. Resolución de un sistema sensor

En la práctica, para poder categorizar los diferentes sensores, principalmente se enfoca la atención en sus características de resolución. Así, se puede definir la resolución de un sistema sensor como su habilidad para discriminar información de detalle. Pero dicho concepto tan amplio, alberga gran variedad de dependencia en función de la dimensión en la que se desea obtener mayor detalle. De esta manera, diferenciamos distintas resoluciones:

**Resolución Espacial.** Este término designa al objeto más pequeño que puede ser distinguido sobre una imagen. Depende de la longitud focal de la cámara y de su altura sobre la superficie. En los sensores óptico-electrónicos, como es el caso del WV2 (WorldView-2), se prefiere utilizar el concepto campo de visión instantáneo (*instantaneous field of view*, IFOV). El IFOV se define como la sección angular que observa el sensor en un momento determinado. La resolución espacial tiene un papel protagonista en la interpretación de la imagen, por cuanto marca, de alguna forma, el nivel de detalle que ésta ofrece [3]. A modo de ejemplo, en la Figura 2.5., se puede observar la resolución espacial ofrecida por satélites diferentes.



Figura 2.5. Resolución espacial de diferentes satélites. (a) QUICKBIRD 2007 (1m), (b) IKONOS 2007 (4m), (c) LANDSAT etm857\_03 (28m). (Fuente: <https://www.cursosteledeteccion.com/tipos-de-sensores-especializados-en-el-medio-marino/resolucionespacial1/>)

**Resolución Espectral.** Indica el número y anchura de las bandas espectrales que puede discriminar el sensor. En este sentido, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral detallada de las distintas cubiertas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objetivo de recoger la señal sobre regiones coherentes del espectro. Bandas muy anchas suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre cubiertas de interés. Hasta hace pocos años, la observación de un número elevado de bandas espectrales estaba reducida a sensores aeroportados. Sin embargo, hoy en día se goza de disponer de técnicas de teledetección hiperespectral (Figura 2.6.) en plataformas espaciales, abriéndose un futuro muy prometedor en el análisis de recursos terrestres, aunque no para estudiar a escala local al no poder alcanzar resoluciones espaciales muy elevadas. Hay que destacar también, que la elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionado con los objetivos de su diseño [3].

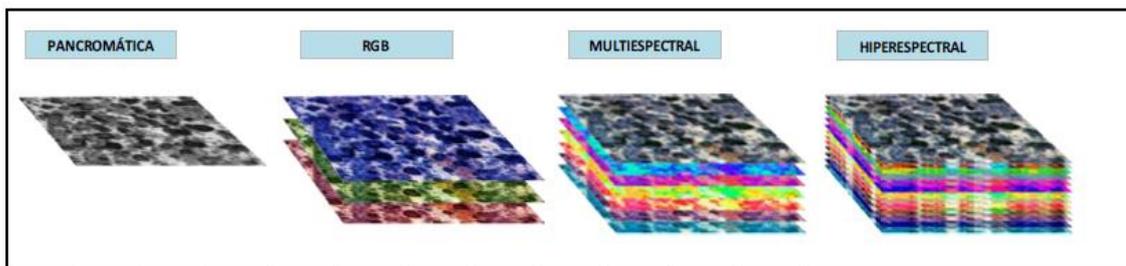


Figura 2.6. Tipos de resolución espectral.

**Resolución Radiométrica.** Hace mención a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. Para los equipos digitales, la imagen se codifica en un formato binario, por lo que la resolución radiométrica suele identificarse con el rango posible de valores que almacena el sensor, medido como el número de bits que necesita cada valor numérico para almacenarse [3].

**Resolución Temporal.** Este concepto alude a la frecuencia de cobertura que proporciona el sensor. Es decir, a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma, así como del diseño del sensor, principalmente del ángulo total de apertura y el

ancho de exploración (swath). Conviene también tener en cuenta que la resolución temporal efectiva dependerá también de las condiciones atmosféricas, ya que con sensores ópticos es posible observar áreas cubiertas por las nubes.

**Resolución Angular.** Es el término más reciente, que refiere a la capacidad de un sensor para observar la misma zona desde distintos ángulos. Tradicionalmente, se ha asumido que las cubiertas presentan una reflectividad lambertiana, lo que implica que ofrecerían una señal similar independientemente del ángulo con que se observan. En la práctica no es así, especialmente para algunas superficies que presentan fuertes efectos de reflectividad bidireccional. Una manera de modelar estos efectos es observar la cubierta desde distintas posiciones, facilitando así su mejor caracterización. También la observación multiangular resulta de gran interés para estimar algunas variables atmosféricas, ya que al variar el ángulo de mira se está observando la superficie con distinto espesor atmosférico, variando en consecuencia los procesos de absorción y dispersión [3].

A modo de ejemplo, incluyendo los sensores que se van a utilizar, en la Figura 2.7. se muestra el compromiso que adquiere cada plataforma entre las resoluciones espacial y espectral.

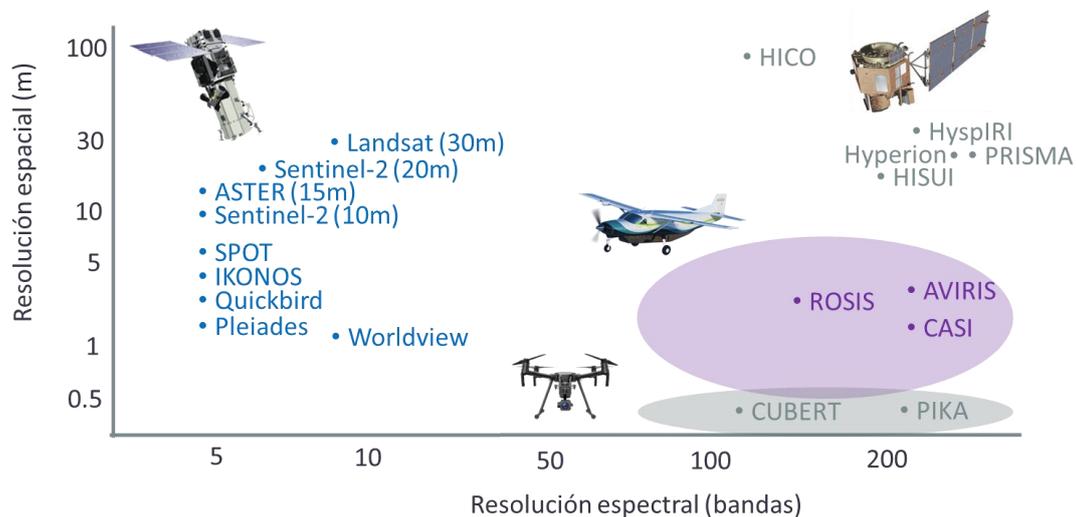


Figura 2.7. Resolución espacial/espectral de diferentes sensores de teledetección.

## 2.2. Satélite WorldView-2

Como se ha introducido, la mayor parte este Trabajo de Fin de Grado se emplea sobre una imagen captada por el satélite WorldView-2 (Figura 2.8.). Por ello, se describirán las características generales y espectro-temporales más relevantes a continuación.



Figura 2.8. Modelo satélite WorldView-2. (Fuente: <https://www.satimagingcorp.com/satellite-sensors/worldview-2/>)

El satélite WV2 fue lanzado por la compañía americana DigitalGlobe el 9 de octubre de 2009 a unos 770 kilómetros de altura. Convirtiéndose en el primer satélite de alta resolución comercial, de 8 bandas multiespectrales con 1,85m de resolución y una pancromática de 46cm de resolución [4].

Con la mejora de su agilidad, barriendo hacia atrás y hacia delante, WV2 es capaz de recoger áreas muy grandes de imágenes multiespectrales en una sola pasada. De hecho, puede recolectar cerca de 1 millón de km<sup>2</sup> todos los días. La combinación de la gran altitud y mayor agilidad le permite volver a visitar normalmente cualquier lugar de la tierra en 1,1 días, siendo su periodo orbital de 100 minutos [5].

Resumiendo, las principales ventajas frente a otros satélites de teledetección de alta resolución son las siguientes [5]:

- Mayor resolución espectral. WorldView-2, junto con el WorldView-3, es el único satélite comercial en proporcionar alta resolución espacial e imágenes multiespectrales de 8 bandas. Así, además de las cuatro bandas multiespectrales típicas (azul, verde, rojo e IR cercano), incluye 4 bandas adicionales para mejorar el análisis multiespectral y permitir nuevas aplicaciones.
- Mayor agilidad. La serie de satélites WorldView son las primeras plataformas comerciales con capacidad para controlar los momentos de fuerza generados por los giroscopios. Esta tecnología de alto rendimiento proporciona una aceleración hasta 10 veces más que la de otros actuadores de control de actitud y mejora la maniobrabilidad y la capacidad de orientación.
- Mayor capacidad y revisita. Gracias a su mayor agilidad, WV2 puede obtener imágenes multiespectrales de diferentes áreas en un solo pase. Siendo su capacidad de exploración de hasta 975.000 kilómetros cuadrados por día. La combinación de esta agilidad y la altura orbital le permite tener una revisita a cualquier zona en 1.1 días.
- Mejor precisión. La tecnología avanzada de posicionamiento de WorldView-2 es lo que permite mejoras significativas en su precisión de geolocalización. La especificación de precisión se ha mejorado hasta 6.5m CE90 sin ningún tratamiento

adicional, uso de modelo de elevación, ni puntos de control en tierra, pudiendo llegar hasta 2m con datos adicionales.

En cuanto a las características espectrales, WV2 es capaz de generar una imagen pancromática de alta resolución espacial, con una respuesta reducida para el azul y el infrarrojo, y ocho bandas de alta resolución espectral y de peor resolución espacial, como se muestra en la Figura 2.9.

Las bandas multiespectrales son capaces de proporcionar una precisión de color excelente, permitiendo el desarrollo de nuevas aplicaciones. Además de las cuatro bandas multiespectrales tradicionales en el azul, verde, rojo e infrarrojo cercano, se incluyen cuatro bandas adicionales: una centrada en longitudes de onda más corta que el azul, aproximadamente en 427 nm; una banda amarilla, a 608nm; una banda en el borde del rojo, centrada estratégicamente en, aproximadamente, 724 nm, al ser el inicio de la parte de alta reflectividad de la respuesta de la vegetación, y una adicional en el infrarrojo cercano, pero a mayor longitud de onda, centrada aproximadamente en 949 nm, que es sensible al vapor de agua atmosférico [6].

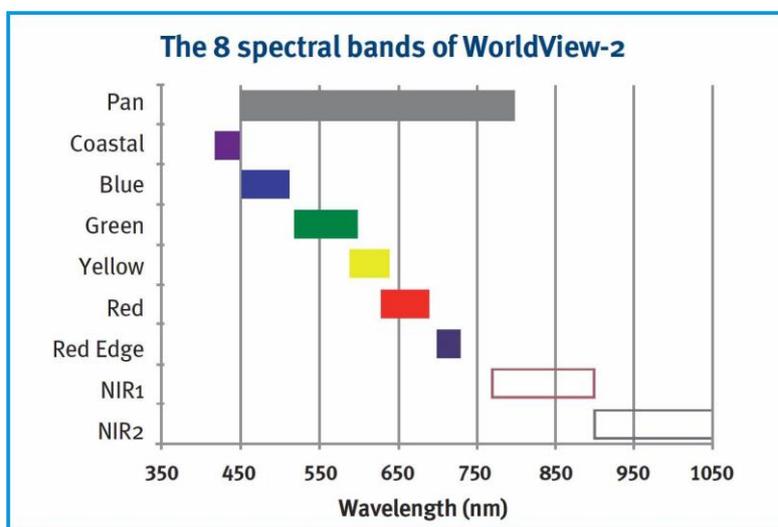


Figura 2.9. Bandas espectrales del WV2. (Fuente: <https://www.satimagingcorp.com/satellite-sensors/worldview-2/>)

Las principales características de las nuevas bandas son [6]:

- Azul costero (400-450 nm): Ayuda en la realización de análisis de cubiertas vegetales. Mayor penetración en el agua. Muy útil en los estudios batimétricos. Tiene el potencial para mejorar las técnicas de corrección atmosférica.
- Amarillo (585-625nm): Muy importante para la clasificación, ya que es un color abundante en la vegetación. Detecta dicha “amarillez” tanto en tierra como en agua.
- Borde rojo (705-745 nm): Muy valiosa para medir la salud de plantas y ayudar en la clasificación de la vegetación.
- Infrarrojo cercano – NIR2 (860-1040nm): Se ve menos afectada por la influencia de la atmósfera. Permite el análisis de la vegetación y estudios de la biomasa.

### 2.3. Dron DJI Matrice 600

Un dron es un vehículo aéreo no tripulado (VANT) controlado a distancia. Aunque sus comienzos fueron con fines militares, actualmente se utilizan para llevar a cabo múltiples tareas como vigilancia, fotografía y ocio, entre otras. La ciencia no ha desaprovechado la oportunidad

y ha incursionado con bastante éxito en el uso de estas plataformas colocando diversos instrumentos de medición en los VANT, lo que ha permitido reducir el coste de recolección de grandes cantidades de datos de alta calidad. Como resultado, cada vez más académicos en diversas disciplinas como lo son las Ciencias de la Tierra están obteniendo información mediante sensores aéreos con mayor frecuencia en aras de generar mayores beneficios a la sociedad.

A través de esta nueva tecnología, se desarrolló la última parte del proyecto. Utilizando el dron Matrice 600 (M600), que es una nueva plataforma aérea de DJI diseñada para fotografía profesional y aplicaciones industriales [7]. En la Figura 2.10. se muestran las imágenes del dron durante la campaña de captación de imágenes en Cabrera.



Figura 2.10. Plataforma DJI Matrice 600 durante la captación de imágenes en Cabrera.

#### 2.5.1. Cámara hiperespectral Pika-L

Para la obtención de las imágenes para este trabajo, fue necesario equipar la plataforma mencionada anteriormente con la cámara hiperespectral Pika-L, fabricada por Resonon [8]. Esta familia de cámaras genera imágenes de barrido transversal que escanean la luz visible, ultravioleta, y los rangos espectrales del infrarrojo cercano. Son robustos y rentables, de alta precisión, baja distorsión, baja difusión de luz y una excelente calidad de imagen.

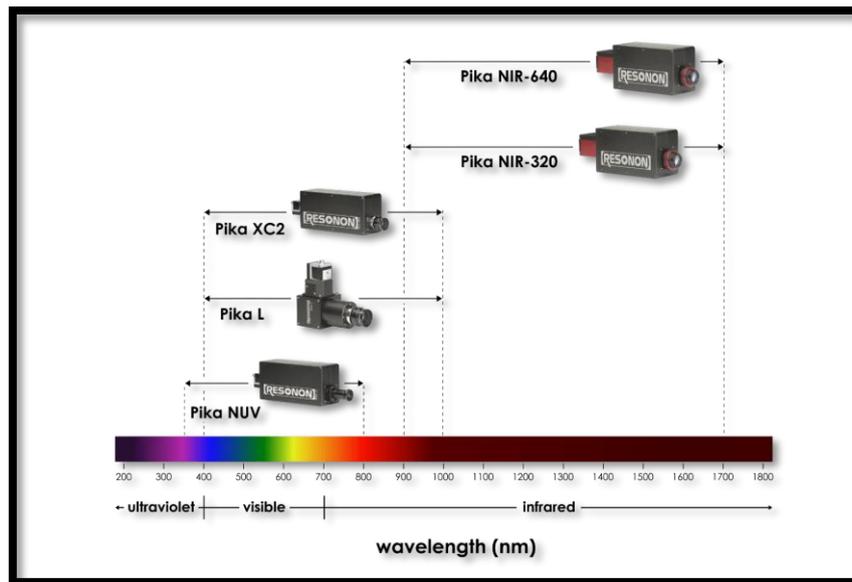


Figura 2.11. Bandas utilizadas por los modelos Pika. [8]

En concreto, Pika-L tan solo pesa 0.6 kg, haciéndola ideal para aplicaciones de sensores remotos. El sistema de a bordo completo pesa 1,6 kg y se ajusta a muchos drones disponibles en el mercado. Posee un rango espectral desde los 400nm hasta los 1000nm, como se observa en la Figura 2.11., con resolución espectral de 2,1nm. Además, cuenta con 281 canales espectrales repartidos por los 600nm de su banda de captación, y 900 canales espaciales, donde la imagen es reproducida en 561 píxels de 5,86  $\mu\text{m}$  de tamaño cada uno [8]. En este aspecto, hay que destacar que esta cámara es configurable y, para garantizar una relación señal a ruido adecuada, puede variarse la resolución espectral. Específicamente, la configuración seleccionada para el PN Cabrera se basó en la captación de 150 canales de 4nm de ancho espectral y resolución espacial de 10cm.



---

## Capítulo 3

# TÉCNICAS DE PROCESADO

---



En este capítulo se describen los diferentes procesos que se emplean para eliminar cualquier anomalía detectada en la imagen, ya sea, por ejemplo, en su localización o en la radiometría de los píxeles que la componen. También se abordarán las etapas de post-procesado en las que se clasifica la información proporcionada por cada píxel.

### 3.1. Corrección geométrica

Cualquier imagen adquirida por un sensor remoto, ya sea aéreo o espacial, presenta una serie de alteraciones debidas a muy variados factores. Concretamente, éste es el caso de las distorsiones geométricas originadas por la plataforma. Pese a la gran estabilidad de un satélite en observación, muy superior al que ofrece un avión o dron, pueden producirse pequeñas variaciones en la altitud de su órbita, en la velocidad, o en la orientación de cualquiera de sus tres ejes: alabeo (roll), cabeceo (pitch), giro lateral (yaw). En el primer caso se producen cambios en la escala de la imagen, mientras que en el segundo distorsiones de distinto tipo en su geometría de adquisición. Se pueden considerar factores no sistemáticos, puesto que aparecen de forma esporádica y son, por ello, difícilmente predecibles y complejos de modelar. Por otro lado, también, el relieve de la tierra, su esfericidad y su rotación, provocan distorsiones en la toma de la imagen. En nuestro caso, todas estas correcciones vienen aplicadas inicialmente por DigitalGlobe en la imagen WorldView-2 suministrada, ya que algunos problemas se solventan rutinariamente en los centros encargados de la recepción, preprocesado y distribución de las imágenes [3]. Y en cuanto al dron, la empresa también usa software para eliminar dentro de cada franja de exploración estas distorsiones geométricas.

### 3.2. Corrección radiométrica

Por otra parte, varios factores de distorsión pueden deberse al propio funcionamiento del sensor. Por ejemplo, la falta de calibración entre detectores. La cual provoca un desajuste en la traducción uniforme de la señal detectada, dando como resultado que la misma radiancia se codifique en niveles digitales (ND) diferentes. Esto se conoce como efecto de bandeado y es especialmente perceptible en zonas de baja radiancia [3].

Por ello, las correcciones radiométricas son aquellas técnicas que tienen por objeto modificar los niveles digitales de las imágenes procedentes de los sensores de observación de la Tierra, con el fin de corregir los problemas derivados del funcionamiento de los mismos o convertir los datos en valores físicos. Es decir, a través de los datos crudos de los detectores, convertir los niveles digitales a valores de radiancia.



Figura 3.1. Calibración de reflectividad y radiancia. (Fuente: <http://www.gisandbeers.com/correccion-radiometrica-imagenes-satelite/>)

### 3.2.1 Cálculo de reflectividades

Primero, definimos la reflectividad como la relación entre la energía reflejada y la incidente. Así, el procesado radiométrico se refiere a la obtención del parámetro de reflectividad superficial (ToC) respecto a los datos brutos adquiridos por la cámara. Para ello, primero se realiza una corrección radiométrica de los valores digitales obtenidos por el sensor. Posteriormente se obtiene la reflectividad mediante la conversión de los valores digitales (*ND*) a radiancia (*Rad*), según la ecuación 3.1., y posteriormente la utilización de la medida de irradiancia obtenida por el sistema en el mismo momento de la adquisición de la imagen. La conversión de los ND almacenados en una imagen original a variables físicas es un paso previo que resulta de gran utilidad en múltiples fases de la interpretación de imágenes, ya que permite trabajar con variables físicas de significado estándar. Así, la reflectividad o la temperatura son variables físicas comparables entre lugares y fechas, lo que hace más sólida la interpretación de los datos, garantizando la compatibilidad multitemporal y el análisis integrado de distintos sensores, siempre que abarquen las mismas bandas del espectro [3].

$$Rad = ND \times Gain + offset \quad (3.1.)$$

### 3.3. Corrección atmosférica

La influencia atmosférica no afecta por igual a los dos componentes del cálculo de la reflectividad: flujo descendente y ascendente, ya que el espesor de la atmósfera que atraviesan es distinto (Figura 3.2.). Además, hay que considerar que a la irradiancia solar directa se le suma la difusa, procedentes de otros objetos vecinos. En definitiva, la radiancia que recibe el satélite no es la misma que sale del suelo. Siendo ésta la que interesa, ya que pretendemos medir la reflectividad de la cubierta, no la influida por la atmósfera.

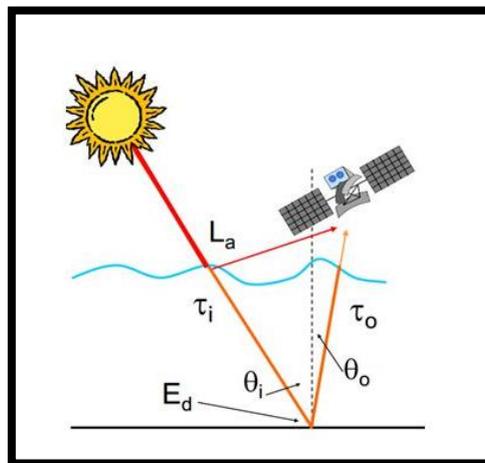


Figura 3.2. Efectos atmosféricos sobre el cálculo de la reflectividad.

Hasta el momento, las correcciones atmosféricas se han abordado siguiendo cuatro procedimientos [3].

1. A partir de medidas simultáneas a la captación de los datos de teledetección, pero rara vez están disponibles.
2. A partir de imágenes de otros sensores, aunque todavía hay pocas experiencias en este procedimiento.
3. A partir de modelos físicos de transferencia radiactiva, que suelen basarse en una serie de modelos de atmósferas estándar.

#### 4. A partir de datos de la propia imagen.

En el entorno en el que se desarrolla el trabajo, es decir, en zonas de agua, la corrección atmosférica es crítica dada la baja reflectancia emitida. Por ello, se emplean modelos atmosféricos avanzados, como el FLAASH, que será el utilizado en este Trabajo Fin de Grado.

### 3.4. Enmascaramiento

Enmascarar es la técnica utilizada para eliminar aquellos píxeles que no son útiles en nuestra área de estudio. Es necesario eliminar todos los píxeles de tierra, barcos o nubes para que el clasificador solamente estime sobre la zona de agua. Para ello, se les da valor cero y quedan anulados a los ojos de los algoritmos de clasificación.

### 3.5. Clasificación digital

Supone la parte culminante del trabajo, ya que como fruto de la clasificación digital se obtiene la cartografía e inventario de las categorías objeto de estudio, que es el objetivo perseguido. En la clasificación, la imagen multibanda se convierte en otra imagen del mismo tamaño y características de las originales, con la importante diferencia de que el ND que define cada píxel no tiene relación con la radiancia o reflectancia detectada por el sensor, sino que se trata de una etiqueta que identifica la categoría asignada a ese píxel [3].

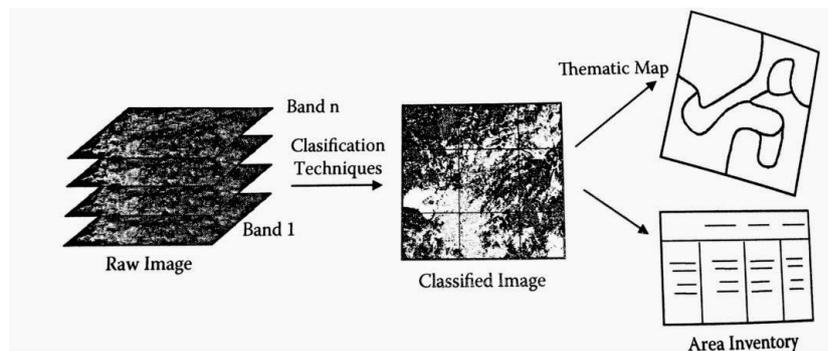


Figura 3.3. Fundamentos de la clasificación digital. (Fuente: <http://bauldegeometica.blogspot.com/2014/05/clasificacion-de-imagenes-digitales.html>)

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo a la forma en que son obtenidas las estadísticas de entrenamiento.

- Método Supervisado:

El método supervisado parte de cierto conocimiento de la zona de estudio, adquirido por experiencia previa o por trabajos de campo. Esto permite al intérprete delimitar sobre la imagen unas áreas suficientemente representativas de cada una de las categorías que componen la leyenda. Estas áreas se denominan áreas de entrenamiento, donde a partir de ellas se caracterizan cada una de las clases, para asignar más tarde al resto de los píxeles de la imagen a una de esas categorías en función de la similitud de sus ND con los extraídos como referencia [3].

- Método No Supervisado:

En este método no se supone un conocimiento previo de la zona de estudio y, por tanto, no se entrena el clasificador. Las categorías espectrales no se pueden equiparar a las clases informacionales que podemos deducir, por lo que nos resta interpretar el significado temático de esas categorías espectrales.

Para la realización de este Trabajo de Fin de Grado se siguió el método supervisado, el cual se compone de tres etapas: fase de entrenamiento, fase de asignación y fase de verificación.

### 3.5.1. Fases de entrenamiento

La clasificación digital supervisada se inicia caracterizando los patrones que definen en la imagen las distintas categorías objetivo. Esto se consigue, a través de una experiencia previa, identificando diferentes rasgos en la zona de interés, como pueden ser su tono, textura, situación o tamaño. También, existe una caracterización basada en los valores numéricos de los píxeles. Esto es, se trata de obtener el rango de ND que identifica a cada categoría, para todas las bandas que intervienen en la clasificación [3].

Como ya se comentó, hay ciertos factores que introducen una distorsión en el comportamiento espectral medio de cada cubierta. Esto se traduce a variaciones en sus valores de ND, aproximando los valores medios de diferentes clases entre sí y complicando la diferenciación mediante valores de ND. Por ello, la fase de entrenamiento resulta ciertamente compleja: se trata de definir con rigor cada una de las categorías o clases que pretendan discriminarse, teniendo en cuenta, como en la Figura 3.4., su propia variabilidad en la zona de estudio.

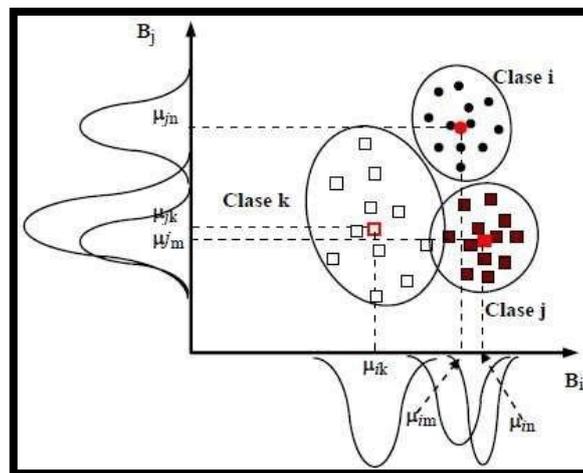


Figura 3.4. Relaciones entre clases y nivel espectral. (Fuente:

<https://ingeoexpert.com/articulo/clasificaciones-de-imagenes-de-satelite/?v=04c19fa1e772>)

Independientemente del método empleado en definir la fase de entrenamiento, antes de abordar la fase de asignación conviene reflexionar sobre la separabilidad de las categorías seleccionadas. En otras palabras, es preciso evaluar la viabilidad de que esas categorías puedan clasificarse sin grave riesgo de error, ya que si dos o más clases son muy similares habría una gran probabilidad de confusión entre ellas. Por lo que resulta aconsejable confirmar que las estadísticas de entrenamiento han sido correctamente deducidas.

Existen varios métodos, tanto gráficos como numéricos, para evaluar las estadísticas de entrenamiento. Aquí se abordará el utilizado en este Trabajo Fin de Grado, ésta es la distancia de Jeffries-Matusita (JM). La distancia JM entre un par de distribuciones de probabilidad (clases espectrales) se define como [3][9][10]:

$$J_{ij} = \int \left( \sqrt{\rho(r|\omega_i)} - \sqrt{\rho(r|\omega_j)} \right)^2 dr \quad (3.2.)$$

Ésta es una expresión que cuantifica la suma de las distancias al cuadrado entre pares de valores de las distribuciones de probabilidad para el par de clases  $\omega_i, \omega_j$ .  $C_i$  y  $C_j$  son las matrices de varianza-covarianza de las categorías  $i$  y  $j$ ;  $m_i$  y  $m_j$  son los vectores de medias correspondientes a las mismas categorías y bandas. Para las clases de distribución normal se convierte en:

$$J_{ij} = 2(1 - e^{-B_{ij}}) \quad (3.3.)$$

donde

$$B_{ij} = \frac{1}{8}(m_i - m_j)^r \left[ \frac{c_i + c_j}{2} \right]^{-1} (m_i - m_j) + \frac{1}{2} \ln \left[ \frac{|(c_i + c_j)/2|}{|c_i c_j|^{1/2}} \right] \quad (3.4.)$$

que se refiere a la distancia de Jeffries-Matusita y cuyo valor oscila entre 0 y 2, siendo 2 la máxima distancia de separabilidad sin errores.

### 3.5.2. Fase de asignación

En esta fase se trata de asociar cada uno de los píxeles de la imagen a una de las clases previamente seleccionadas. Esta asignación se realiza en función de los ND de cada píxel, para cada una de las bandas que intervienen en el proceso. Fruto de esta fase saldrá una nueva imagen, cuyos ND expresen la categoría temática a la que se ha adscrito cada uno de los píxeles de la imagen original.

En este Trabajo Fin de Grado, se emplearán los siguientes tres algoritmos de clasificación. Pues son ampliamente utilizados en teledetección, y serán descritos a continuación.

#### 3.5.2.1. Maximun Likelihood (ML)

Este método de máxima probabilidad considera que los ND en el seno de cada clase se ajustan a una distribución normal. Esto permite describir esa categoría por una función gaussiana, según se muestra en la Figura 3.5., a partir de su vector de medias y matriz de varianza-covarianza, extraído durante la fase de entrenamiento. Esto permite calcular la probabilidad de que un píxel pertenezca a esa categoría, conociendo sus valores en las distintas bandas que empleamos para clasificar [3].

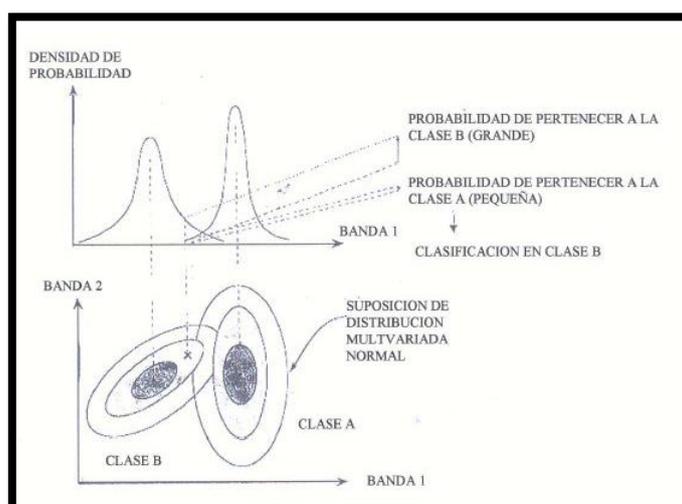


Figura 3.5. Concepto de método de máxima probabilidad. (Fuente: <http://www.teledet.com.uy/tutorial-imagenes-satelitales/maximum-likelihood.htm>)

### 3.5.2.2. Spectral Angle Mapper (SAM)

El algoritmo asignador de ángulo espectral está basado la suposición ideal de que un píxel de imagen representa un determinado material de la cubierta del suelo, y puede asignarse únicamente a una sola clase de la cubierta terrestre. El algoritmo SAM se basa en la medición de la similitud espectral entre dos espectros. Dicha similitud espectral se puede obtener considerando cada espectro como un vector en el espacio q-dimensional, donde q es el número de bandas. El algoritmo SAM determina la similitud espectral entre dos espectros calculando el ángulo entre ambos (ver Figura 3.6.), tratándolos como vectores en un espacio dimensional igual al número de bandas [10].

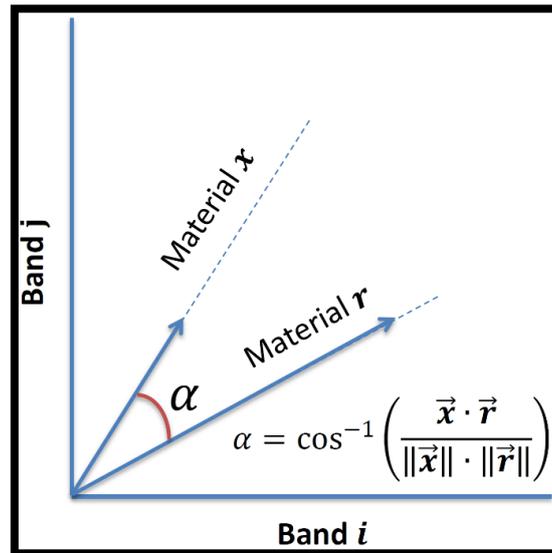


Figura 3.6. Representación del ángulo de similitud entre dos vectores espectrales. (Fuente: <https://upcommons.upc.edu/bitstream/handle/2117/96828/lora%20lopez.pdf?sequence=1&isAllowed=y>)

### 3.5.2.3. Support Vector Machine (SVM)

Una máquina de vectores de soporte es un clasificador discriminativo definido formalmente por un hiperplano separador. En otras palabras, dados los datos de entrenamiento etiquetados, y teniendo en cuenta únicamente aquellos datos en las fronteras entre clases, el algoritmo genera un hiperplano óptimo que categoriza el resto de píxeles de la imagen. En un espacio bidimensional, este hiperplano es una línea que divide un plano en dos partes, donde cada clase se encuentra a cada lado. Esto es, como se ve, a modo de ejemplo, en la Figura 3.7.:

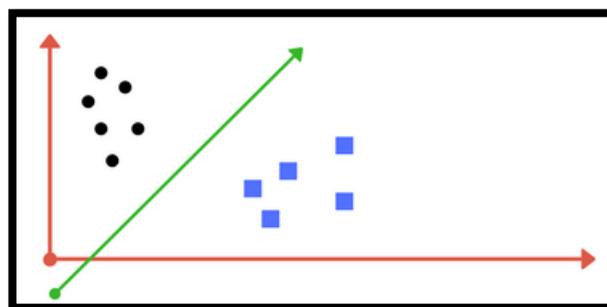


Figura 3.7. representación hiperplano separador de dos clases bien distinguidas. (Fuente: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>)

Pero ahora, qué pasa si la nube de datos se superpone como en la Figura 3.8., haciéndolo aún más complejo.

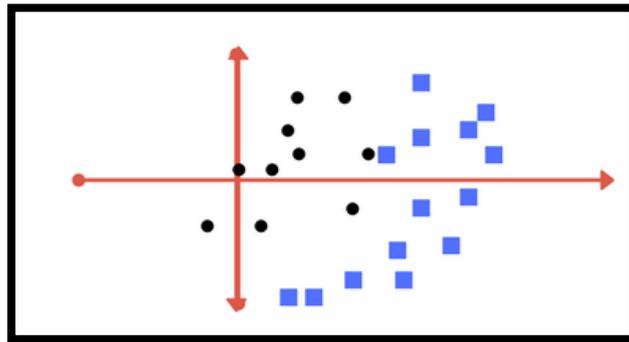


Figura 3.8. Nube de datos superpuestas. (Fuente: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>)

Para ello existen dos soluciones, representadas en la Figura 3.9. En la imagen 1 se toleran puntos atípicos y en la imagen 2 se trata de lograr tolerancia 0 con una partición perfecta.

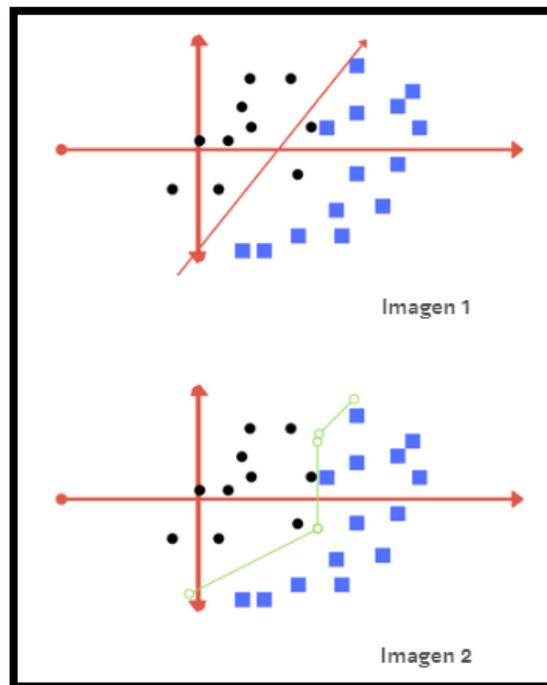


Figura 3.9. Diferentes soluciones de hiperplano frente a datos superpuestos. (Fuente: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>)

En la aplicación del mundo real, encontrar la clase perfecta para el millón de datos de entrenamiento requiere mucho tiempo. A este compromiso se le llama parámetro de regularización. Estos son parámetros de ajuste en el clasificador SVM. Variando aquellos, podemos lograr una considerable línea de clasificación no lineal con mayor precisión en un tiempo razonable [11].

Estos parámetros vienen regulados por las funciones kernel, que son las transformadas que permiten esa conversión de clasificación no lineal en el espacio dimensional original a clasificación lineal en un espacio dimensional mayor. Las funciones kernel más utilizadas son:

- Kernel lineal:

$$K(x_i, x_j) = x_i^T x_j \quad (3.5.)$$

- Kernel polinómico de grado-d:

$$K(x_i, x_j) = (\gamma x_i^T x_j + \tau)^d, \gamma > 0 \quad (3.6.)$$

- Función de base radial gaussiana (RBF):

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (3.7.)$$

- Kernel sigmoideal:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + \tau) \quad (3.8.)$$

donde los parámetros  $\gamma$ ,  $\tau$  y  $d$  se les denomina parámetros del kernel.

### 3.5.2. Fase de Verificación

Una vez obtenido el mapa temático como resultado de la clasificación, ya sea visual o digital, resulta obligado verificar la calidad del mapa clasificado, de cara a comprobar la validez tanto del producto generado como del método propuesto.

Para el caso de verificar cuantitativamente una imagen clasificada, habitualmente se dispone de un listado de puntos de verificación, para los que se posee tanto su cobertura real como la deducida por la clasificación. Con esta lista puede generarse una tabla, denominada *matriz de confusión*, puesto que recoge los conflictos que se presentan entre categorías. En esta matriz las columnas suelen indicar las clases de referencia, y las filas las categorías deducidas de la clasificación. Lógicamente, ambas tendrán el mismo número y significado. La diagonal de esta matriz expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras que los marginales suponen errores de asignación.

El interés de estas tablas de confusión proviene de su capacidad para plasmar los conflictos entre categorías. De esta forma, no solo conocemos la fiabilidad global de la clasificación, sino también la exactitud conseguida para cada una de las clases, así como los principales conflictos entre ellas.

Tabla 3.1. Ejemplo de matriz de confusión.

		Decisiones obtenidas por SVM + RBF: clasificación uno versus todos					
		Avenida	Edificios	Industria	Naturaleza	Residencial	Agua
Etiquetas	Avenida	37	7	4	0	0	2
	Edificios	8	29	6	0	5	2
	Industria	4	7	30	0	3	6
	Naturaleza	0	0	0	49	1	0
	Residencial	0	2	3	0	45	0
	Agua	0	1	2	0	1	46

---

## Capítulo 4

# **GENERACIÓN DEL MAPA DEL FONDO COSTERO MEDIANTE IMAGEN SATÉLITE**

---



#### 4.1. Datos

Para la generación de este primer mapa del fondo marino, se ha utilizado la imagen de la Figura 4.1. Se trata de una imagen multispectral de muy alta resolución captada por el satélite WorldView-2 el día 1 de septiembre de 2016 a las 10:29 horas. Es una imagen que abarca la totalidad del Parque Nacional de Cabrera, cuya superficie total recogida es de 40 km<sup>2</sup>.



Figura 4.1. Imagen del PN Cabrera captada por el satélite WV2.

La imagen se compone por un total de 3164 columnas y 5193 filas, con una resolución espacial de 2 metros, como se observa en la Tabla 4.1.

Tabla 4.1. Información de los metadatos de la imagen en cuestión.

	Map Info
Type	Projected
Pixel Tie Point X	0.5
Pixel Tie Point Y	0.5
Map Tie Point X	492327.0
Map Tie Point Y	4340257.0
Pixel Size X	2.0
Pixel Size Y	2.0
Units	Meters
Rotation	0.0

Esto resulta curioso, pues si volvemos la vista a las especificaciones del WV2 recordamos que su resolución espacial es de 1.85 metros. Dicha variación se justifica al saber que el satélite cuenta con un sistema de visión angular, que le permite observar la misma zona desde distintos ángulos. Muy útil cuando no se tiene visión directa con el área de interés o simplemente se quiere volver a captar una zona determinada antes de tener que cumplir el periodo de revisita. Pero, por otro lado, al variar el ángulo de apuntamiento del sensor, el área observada se incrementa. Y esto implica distorsiones y deformaciones en los píxeles capturados. Justificando los 2 metros de resolución espacial dado que la imagen se captó con 24° de ángulo off-nadir.

En términos de pre-procesado, DigitalGlobe ofrece una amplia gama de productos en función de las aplicaciones que vaya a tener la imagen. Por ello, el producto contratado para nuestro estudio se trata de una Imagen Estándar Ortho Ready. Como se puede observar, según la Tabla 4.2., se trata de un producto en el que ya le han sido aplicadas las correcciones radiométricas y de georrectificación, pero a la que se ha dejado pendiente la ortorectificación que permite compensar los errores asociados a la topografía. Aunque cuenta con los datos necesarios preparados para cuando fuese oportuno, dejándolo al deseo del usuario. Proceso que a nosotros no nos hizo falta aplicar por tratarse de un área de mar nuestra zona de estudio.

Tabla 4.2. Gama de productos para WV2. (Fuente: <https://www.geosoluciones.cl/documentos/worldview/DigitalGlobe-Core-Imagery-Products-Guide.pdf>)

Core Products	Accuracy (CE90)	Processing			Geographic Availability
		Radiometrically and sensor corrected	Georectified	Orthorectified	
Basic	5 m – 23 m*	●			Worldwide
Basic Stereo Pair	5 m*	●			Worldwide
Standard	5 m – 23 m*	●	●		Worldwide
Ortho Ready Standard	5 m – 23 m*	●	●		Worldwide
Ortho Ready Standard Stereo	5 m*	●	●		Worldwide
Vision Premium Precision Aerial	2.7 m – 5.4 m	●		●	Lower48 US + Western EU
Vision Premium Precision	4.2 m	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)
Vision Premium Mapping	10.2 m	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)
Vision Premium Display	25.4 m	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)
Vision Precision	4.2 m	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)
Vision Mapping	10.2 m	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)
Vision Display	25.4	●		●	Worldwide, limited to fine DEM coverage (SRTM + USGS NED)

#### 4.2. Calibración radiométrica

Como se acaba de comentar, las correcciones geométricas y radiométricas vienen aplicadas en el producto contratado. Es por ello que tan solo nos hizo falta calibrar la imagen. Primero, transformando los valores digitales en valores de radiancia, empleando la ecuación 3.1. Donde los valores de ganancia y offset se obtuvieron de los metadatos asociados a la imagen, según la Tabla 4.3.

Tabla 4.3. Información espectral de la imagen obtenida.

	Band Names	Wavelengths	FWHM	Radiance Gains	Radiance Offsets
Units		nm	nm	W/(m <sup>2</sup> sr μm)	W/(m <sup>2</sup> sr μm)
1	Band 1	427.3	51.8	0.196525454545	0.0
2	Band 2	477.9	60.8	0.232196132597	0.0
3	Band 3	546.2	69.8	0.154175730159	0.0
4	Band 4	607.8	38.5	0.155877406417	0.0
5	Band 5	658.8	59.3	0.192268815331	0.0
6	Band 6	723.7	39.8	0.132013638677	0.0
7	Band 7	832.5	117.8	0.123799797776	0.0
8	Band 8	908.0	92.5	0.090785481928	0.0

Este proceso permite calibrar dichos valores para eliminar, en la mayor medida que se pueda, los efectos del sensor en la radiancia captada.

### 4.3. Corrección atmosférica

El siguiente paso consiste en eliminar los efectos de la atmósfera que perturban la energía recibida en la plataforma. Como se comentó anteriormente, se sigue un modelo atmosférico avanzado FLAASH.

Para compensar los efectos atmosféricos, parámetros como la distribución de aerosoles, la cantidad de vapor de agua y la visibilidad de la escena deben ser conocidos. Dado que las medidas de estas propiedades atmosféricas raramente están disponibles en el momento de captación de la imagen, se han desarrollado diferentes estrategias. Los métodos más comúnmente utilizados basados en la imagen son el DOS (*Dark Object Subtraction*) [12], que corrige el efecto de la dispersión aditiva, COST (*Cosine of the sun zenith angle*) [13] que además tiene en cuenta el efecto multiplicativo de la transmitancia, y el QUAC (QUick Atmospheric Correction) [14] que está basado en la demostración empírica de que la reflectancia media de diversos materiales no depende de la escena. Por otro lado, el método SMAC (*Simplified Method for the Atmospheric Correction*) [15] es un método semi-empírico diseñado para la corrección atmosférica de series largas de datos adquiridos para alcanzar grandes campos de visión. El ELC (*Empirical Line Calibration*) [16] usa medidas de campo de la reflectancia de la superficie, a partir de una serie de objetos calibrados e invariantes en el tiempo, para estimar la reflectancia en cada banda. Para realizar la corrección atmosférica se desarrolla una ecuación de ajuste por regresión para cada banda de la imagen. Por último, para modelar el efecto atmosférico se han propuesto desarrollos más complejos, basados en un modelo de transferencia radiativa (*Radiative Transfer Code, RTC*) como el MODTRAN (MODerate resolution atmospheric TRANsmision) [17], FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) [18], ATCOR (*ATmospheric CORrection*) [19] y el 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) [20].

El algoritmo de corrección atmosférica Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes (FLAASH) se corresponde con una evolución del código de transferencia radiativa MODTRAN. Así, el modelado de la atmósfera se ejecuta en correspondencia con la elección de uno de los 6 modelos que presenta el estándar de MODTRAN. Cada uno de ellos definidos por la temperatura, presión, densidad y la combinación de diferentes proporciones de H<sub>2</sub>O, O<sub>3</sub>, CH<sub>4</sub>, CO y N<sub>2</sub>O. Los modelos de atmósfera definidos son: *Sub-Artic Winter (SAW)*, *Mid-Latitude Winter (MLW)*, *Tropical (T)*, *Mid-Latitude Summer (MLS)*, *Sub-Artic Summer (SAS)* y *U.S. Standard (US)*. En cuanto al modelo de aerosol, FLAASH proporciona 4 modelos que se basan en el estándar MODTRAN. Dichos modelos se basan en compuestos como agua disuelta, polvo, humo, sal de mar, etc. que se mezclan homogéneamente. Además se caracteriza el crecimiento de tamaño de las partículas de aerosol y sus cambios en el índice de refractividad como función de la humedad relativa. Los cuatro modelos de aerosol definidos son: rural, urbano, marítimo y troposférico. El ángulo de visión y el ángulo solar en el momento de la adquisición, junto con los valores nominales de la elevación superficial, el tipo de aerosol y el rango visible de la escena deben ser especificados. Para tener en cuenta posibles variaciones en la columna de vapor de agua a través de la escena, se establecen una serie de perfiles de agua variables. Para ello MODTRAN4 permite introducir un factor de escala que es aplicado sobre el perfil nominal del agua dentro del modelo de atmósfera especificado. Al igual que hacen otros métodos, antes de obtener los valores de reflectividad corregido se recupera la columna de vapor de agua píxel a píxel. Para ello se utilizan promedios de radiancias en dos conjuntos de canales: unos de absorción y otros de referencia. El primer conjunto centrado en la banda de agua (típicamente a 1.13 $\mu$ m) y el otro se toma en los bordes de dicha banda. En caso de sensores donde las



Valores que se utilizaron posteriormente, como se puede observar en la Figura 4.3, junto con los 120.8° de azimut media del satélite y un ángulo medio off nadir de 24°, para realizar la correspondiente corrección atmosférica.

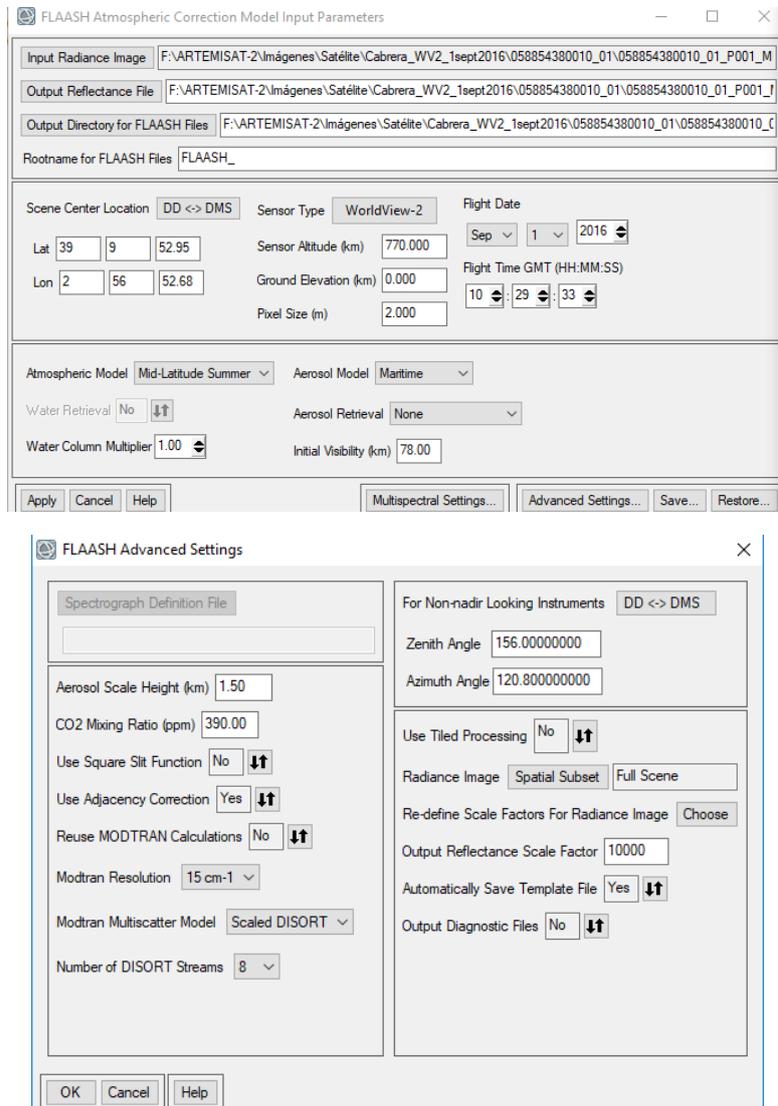


Figura 4.3. Parámetros establecidos para el ajuste FLAASH.

Finalmente, en la Figura 4.4. se muestra el resultado de aplicar las correcciones:



Figura 4.4. Imagen de estudio con las correcciones y calibraciones aplicadas.

#### 4.4. Enmascaramiento

Teniendo la imagen con los preprocesados necesarios aplicados, la siguiente tarea consistió en eliminar todo píxel fuera de nuestra área de interés, con el objetivo de no contaminar las muestras de entrenamiento en los algoritmos de clasificación.

##### 4.4.1 Máscara de profundidad

Como es obvio, y se vio en la Figura 2.2. y 2.3., el agua absorbe radiación, reflejando solamente un limitado rango de frecuencias típicamente en los canales de menor longitud de onda del espectro visible. Lo cual, analizando la imagen y con la ayuda de un mapa batimétrico proporcionado por el Instituto Español de Oceanografía (IEO) [22], se observa que a profundidades superiores a 40 metros es casi imposible apreciar el fondo marino (Figura 4.4.). Por este motivo, se tomó esta profundidad como límite máximo para intentar generar la cartografía del fondo marino. Habitualmente, los estudios existentes en la literatura limitan su zona de estudio hasta profundidades inferiores a 25 o 30 metros. Sin embargo, en este Trabajo Fin de Grado se ha intentado una clasificación a profundidades mayores.

Seguidamente, se procede a enmascarar dichas zonas de agua profunda para que no estorbe el estudio. Primero se cargaron las isobatas de batimetría, se determina la que marca los 40 metros, y se declara el interior de la misma Región de Interés (ROI). Luego, con la región

señalizada, se crea una máscara basada en esa ROI con el programa ENVI. Por último, se aplica dicha máscara a la imagen preprocesada, obteniendo el resultado de la Figura 4.5.



Figura 4.5. Imagen enmascarada a 40 metros de profundidad.

#### 4.4.2. Máscara de tierra, nubes y barcos

Otros aspectos que no nos interesa en nuestra clasificación y trataremos de eliminar de la imagen para evitar errores en la clasificación son:

- Las nubes y los barcos.
- La tierra, porque obviamente nuestro interés reside en el mar.

Se va a empezar por este último. Para enmascarar la tierra se utilizó la banda 7 de infrarrojo cercano (NIR). Dicha banda tiene un valor muy elevado de reflectividad en la tierra, pero sin embargo tiene un valor muy bajo en el mar, ya que el agua absorbe casi por completo esa radiación, como podemos ver en la figura 4.6.

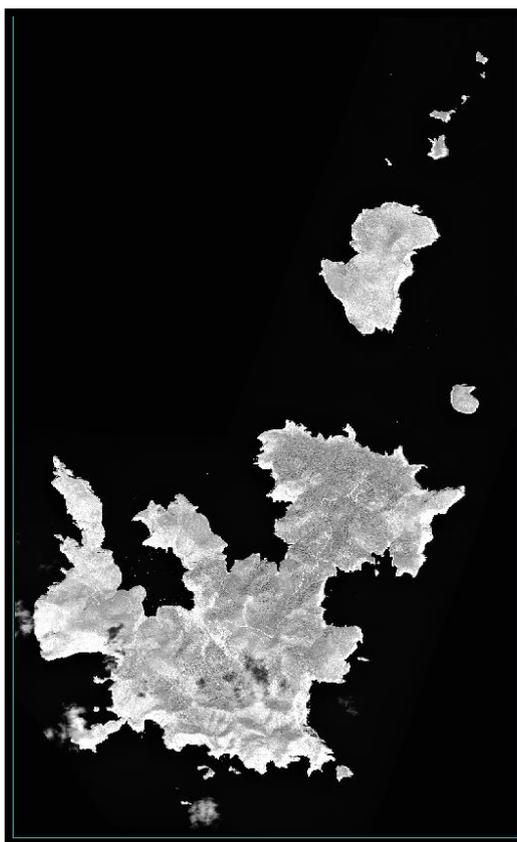


Figura 4.6. Banda 7 de la imagen WV2.

Entonces, gracias a esta banda, a través de su histograma se observan los valores de los píxeles de la tierra y los valores de los píxeles del agua bien diferenciados (ver Figura 4.7.). Y gracias a ello, mirando los valores de los píxeles muy cercanos a la costa, puede establecerse un valor de compromiso que separe ambas clases de la forma más precisa posible, siendo 1000 en nuestro caso.

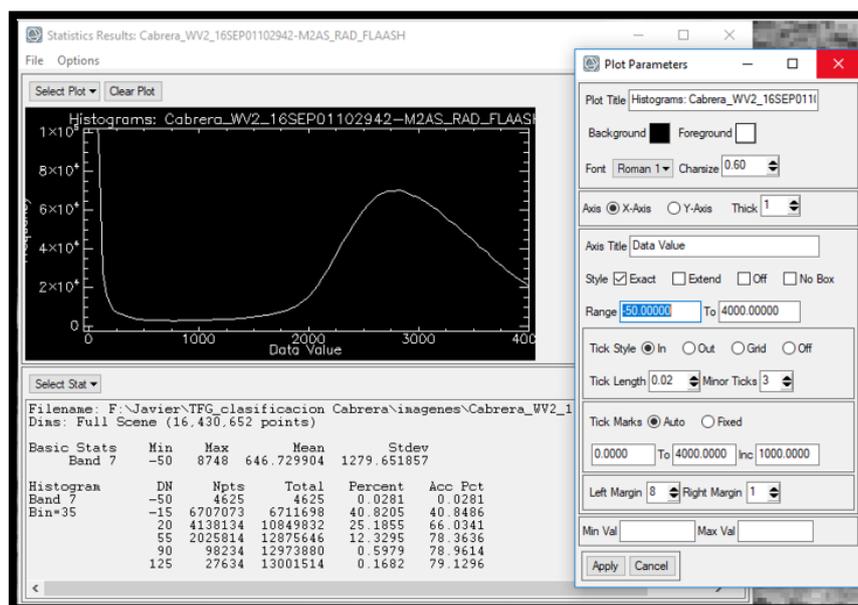


Figura 4.7. Histograma de la banda 7 de la imagen WV2.

Una vez obtenido ese valor, se genera la máscara con la herramienta ENVI, pero esta vez importando un rango de valores, elegidos entre -50 y 1000, y se aplica la máscara creada. Hay que puntualizar que no debería dar reflectividad negativa (-50), pero debido a los parámetros del modelo, a veces para valores muy bajos se obtienen reflectancias negativas. El valor de reflectancia varía entre 0 y 1, pero el ajuste FLAASH aplica un escalado x10.000.

Por último, vemos como ciertas nubes muy finas y algunos barcos se encontraban fuera del rango escogido en la banda 7. Por lo tanto, se procedió a enmascarar de forma manual usando las ROIs. A diferencia que ahora el área de las ROI es precisamente el área que se desea eliminar. Por ello se tuvo que generar dos máscaras, una con las ROIs seleccionadas sobre barcos y nubes, y otra sobre la máscara resultante, pero importándole los valores de su inversa. Finalmente, se puede observar el resultado del proceso de enmascaramiento completo en la Figura 4.8.

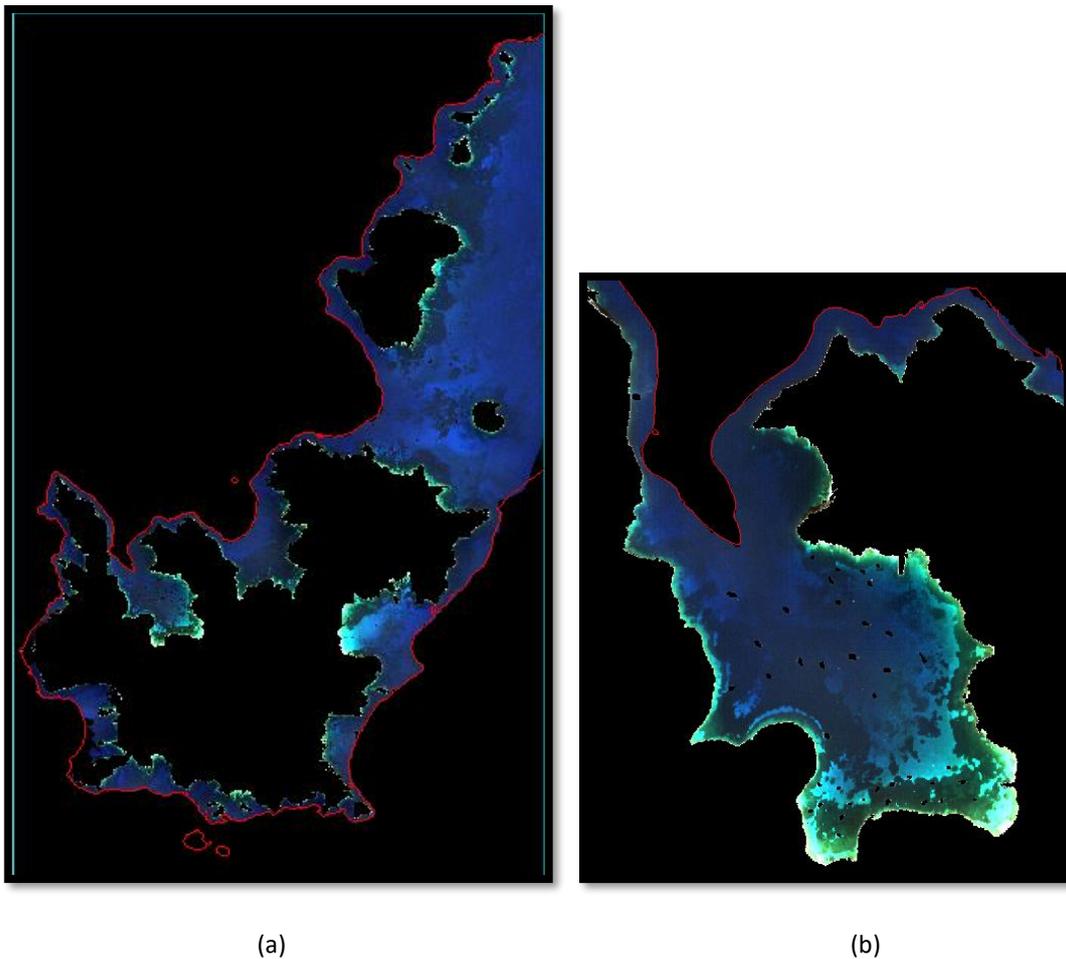


Figura 4.8. Resultado de aplicar las máscaras con isobata de 40 metros definida. (a) imagen completa y (b) zona del Port.

## 4.5. Clasificación

### 4.5.1. ROIs de Entrenamiento

Una vez aplicados todos los procesos sobre la imagen para facilitar al máximo la clasificación, el primer paso va a ser definir las clases de interés. Como se comentó al principio, en este Trabajo de Fin de Grado se sigue un método de entrenamiento supervisado, donde va a ser fundamental el apoyo de los mapas de referencia que actuarán de fuente de conocimiento previo de la zona.

Dichos mapas son el del Instituto Español de Oceanografía en 2011[22] (Figura 4.9) y el generado durante el proyecto LIFE Posidonia en 2005 [1] (Figura 4.10).

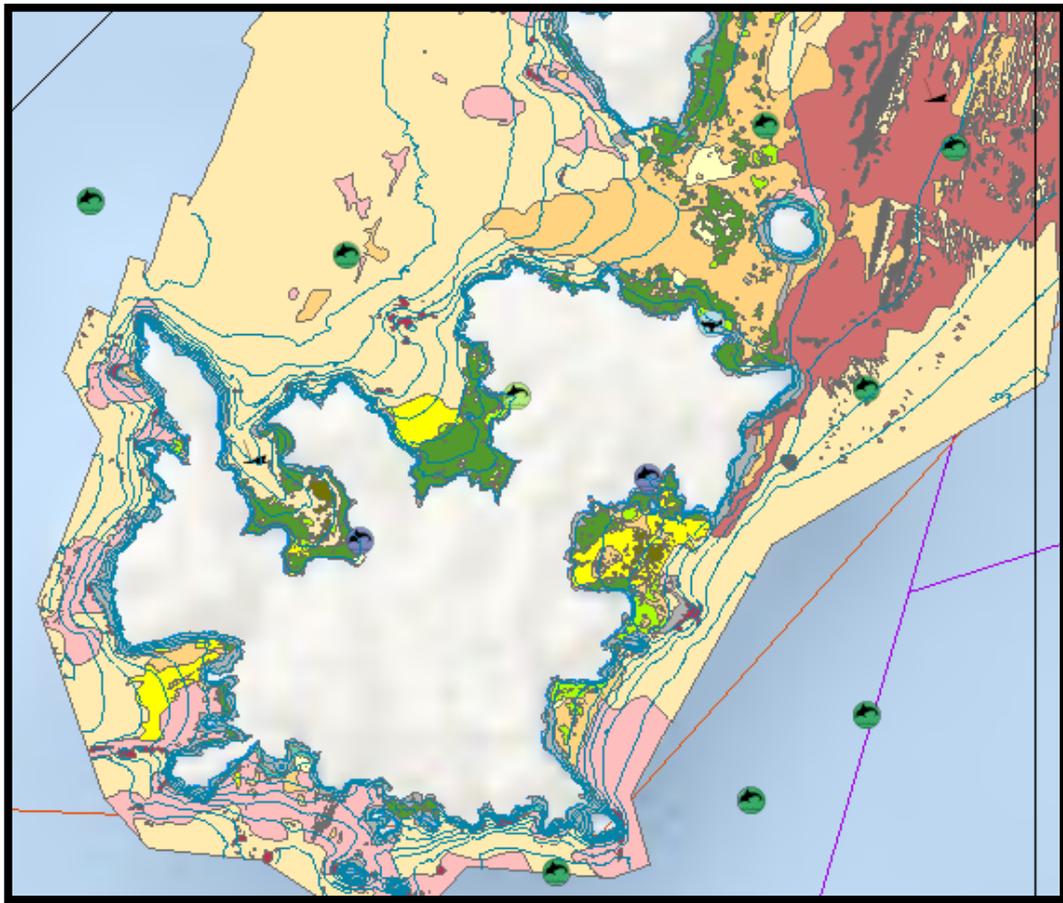


Figura 4.9. Cartografía marina del Parque Nacional Cabrera generada por el Instituto Nacional de Oceanografía.

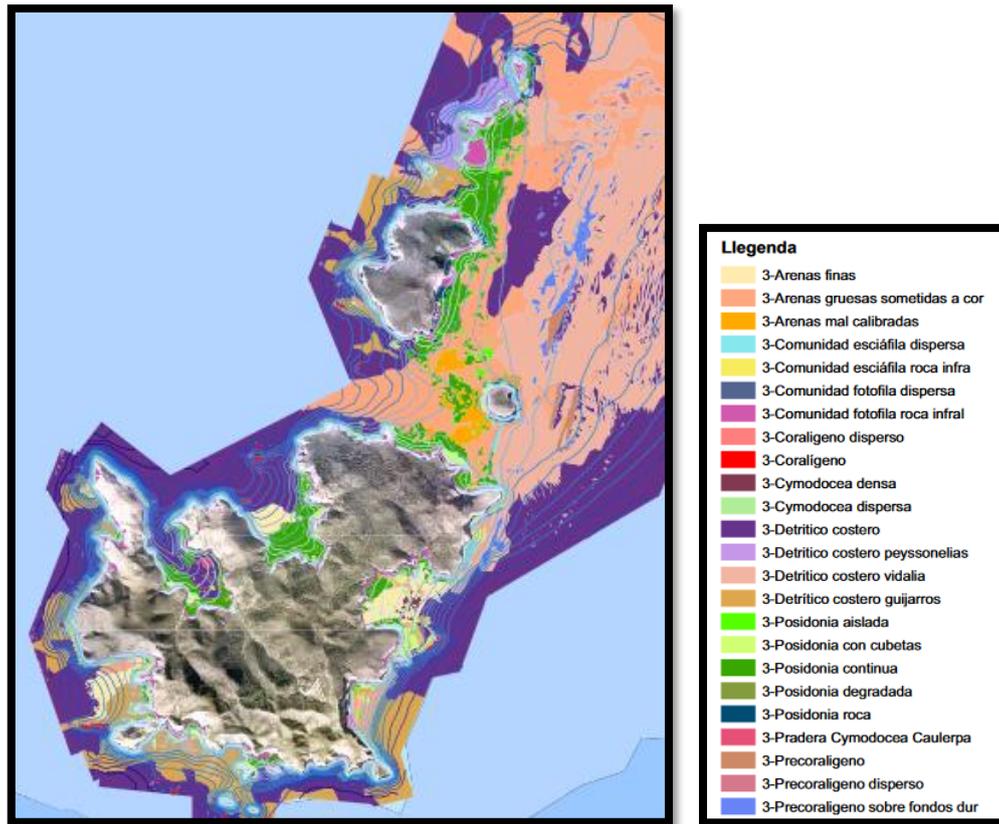
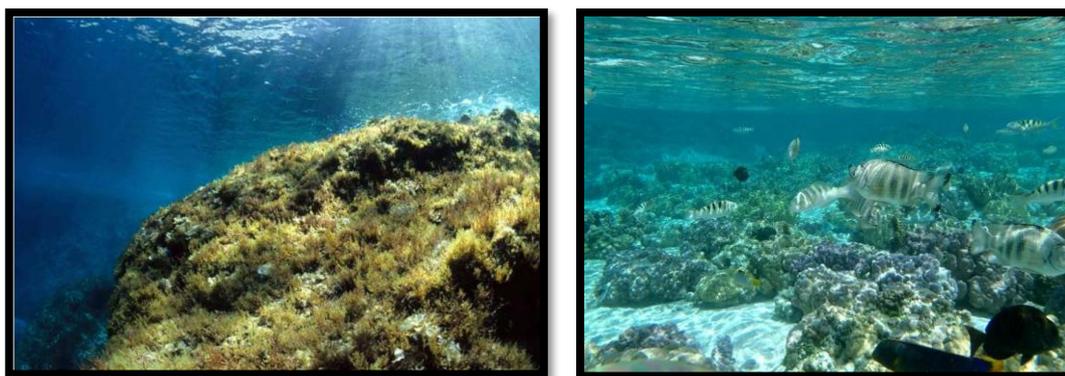


Figura 4.10. Cartografía marina del Parque Nacional Cabrera generada por el Proyecto LIFE Posidonia.

Con esta información fue posible identificar la variedad subacuática del Parque Nacional (ver Figura 4.11). Tomándola como referencia, se pudo definir cuatro clases de interés, mostradas en la Tabla 4.4.

Tabla 4.4. Tabla de clases por colores asignados a la clasificación de la cartografía marina.

Clases/Categorías	Valor RGB	Color
Rocas Infralitorales y Circalitorales	(240, 0, 0)	
Arenas y Fondo Detrítico	(240, 150, 0)	
Posidonia	(0, 153, 0)	
Cymodocea	(95, 57, 95)	
Otros	(255, 255, 255)	



(a)

(b)



(c)

(d)

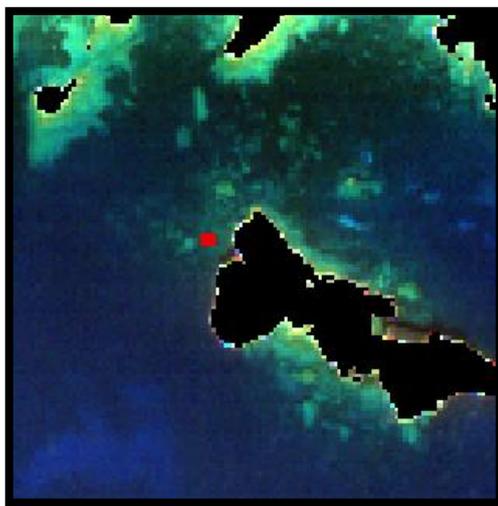
Figura 4.11. Elementos subacuáticos que constituyen el fondo marino del PN Cabrera: (a) Rocas Infralitorales y Circalitorales (Fuente: <https://www.miteco.gob.es>), (b) Arena y Fondo Detrítico (Fuente: <https://mallorca-touristguide.com>), (c) Posidonia (Fuente: <https://www.agenciasinc.es>) y (d) Cymodocea (Fuente: <http://www.seacyprus.org>).

Con los conocimientos necesarios de la zona aportados por las cartografías existentes, se procedió a relacionar varios píxeles con su clase correspondiente, a modo de entrenamiento. Para ello, primero fuimos conscientes de las dificultades que se nos presentaban a medida que se iba avanzando en profundidad. Por eso se tomó la decisión de generar las regiones de interés específicas cada 10 metros de profundidad. Para ello se carga las isobatas maestras de la batimetría proporcionada y dividimos cada clase en 4 sectores. Por ejemplo: Posidonia 0-10m, Posidonia 10-20m, Posidonia 20-30m y Posidonia 30-40m. De esta forma quedaba identificada cada clase a diferentes profundidades, dado el evidente desvanecimiento en la intensidad de la radiancia reflejada. Sobre todo, siempre procurando escoger cada ROI donde la presencia de cada clase fuera más evidente, evitando píxeles conflictivos, como áreas de transición entre materiales distintos.

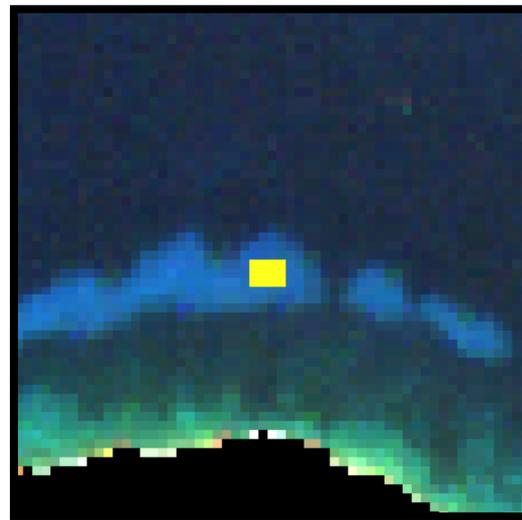
Ya con las ROIs generadas por profundidades, se procedió a unificarlas por categorías, resultando en las 5 categorías base presentadas anteriormente, obteniendo un total de 163 ROIs, repartidas por las diferentes clases según indica la Tabla 4.5. y se muestran en la Figura 4.12. en detalle.

Tabla 4.5. Número de ROIs de entrenamiento por clases.

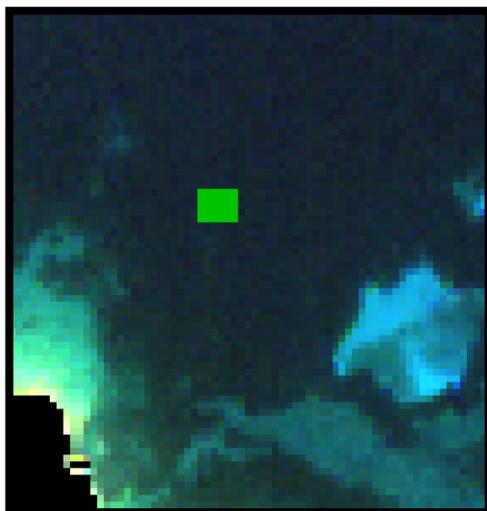
Clases/Categorías	ROIs de entrenamiento
Rocas Infralitorales y Circalitorales	32
Arena y Fondo Detrítico	64
Posidonia	56
Cymodocea	8
Otros	3



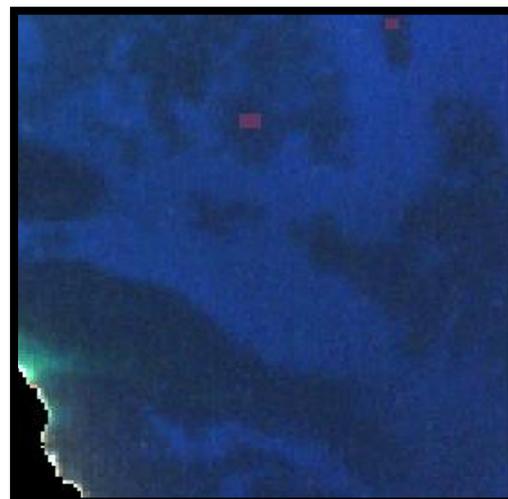
(a)



(b)



(c)



(d)

Figura 4.12. Muestra ejemplo de las Regiones de Interés escogidas para cada clase: (a) Clase Rocas Infralitorales y Circalitorales, (b) clase Arena y Fondo Detrítico, (c) clase Posidonia y (d) clase Cymodocea.

Destacar el bajo número de regiones tomadas para la Cymodocea. Esto se debe primero a que, tomando los mapas de referencia como guía, se observa que no abunda mucho en el fondo costero de Cabrera. Y, luego, dado su gran parecido con la Posidonia, esta diferencia entre ambas solo es claramente apreciable en una determinada zona donde se encuentra la Cymodocea aislada en abundancia y es posible identificarla por la ligereza de su densidad. De resto tiende mucho a la confusión con la Posidonia y, como se declaró, el objetivo de esta fase es no abarcar áreas de posible conflicto.

#### 4.5.2. ROIs de evaluación

Para la elección de las ROIs de evaluación se han seguido criterios similares a los explicados para las ROIs anteriores. Sin embargo, con el fin de obtener una mayor exactitud en la evaluación de la clasificación, se aumenta considerablemente el número de áreas de test escogidas en clases que tendían a la confusión, con respecto a las de entrenamiento. Además, para realizar esta tarea se procuró seleccionar muestras de píxeles diferentes a las tomadas anteriormente. A diferencia de las primeras, esta vez se tomaron un total de 208 muestras, repartidas según se presenta en la tabla 4.6.

Tabla 4.6. Número de ROIs de evaluación por clases.

<b>Clases/Categorías</b>	<b>ROIs de evaluación</b>
<b>Rocas Infralitorales y Circalitorales</b>	27
<b>Arena y Fondo Detrítico</b>	88
<b>Posidonia</b>	73
<b>Cymodocea</b>	17
<b>Otros</b>	3

#### 4.5.3. Separabilidad entre clases y firmas espectrales

En la Figura 4.13 se muestran los índices de separabilidad espectral entre cada una de las parejas de clases escogidas para el entrenamiento, y en la siguiente vemos sus firmas espectrales. Nótese que se obvia la clase "Otros" al tener tan solo un único valor para el cálculo.

```

Input File: Cabrera_atmospheric_allMasks
ROI Name: (Jeffries-Matusita, Transformed Divergence)

Rocas Infralitorales y Circalitorales:
Posidonia: (1.92789454 2.00000000)
Arena y Fondo Detritico: (1.95928716 1.99999853)
Cymodocea: (1.99208368 2.00000000)

Posidonia:
Rocas Infralitorales y Circalitorales: (1.92789454 2.00000000)
Arena y Fondo Detritico: (1.73362781 1.97732483)
Cymodocea: (1.81974340 1.97873009)

Arena y Fondo Detritico:
Rocas Infralitorales y Circalitorales: (1.95928716 1.99999853)
Posidonia: (1.73362781 1.97732483)
Cymodocea: (1.92795467 1.99999999)

Cymodocea:
Rocas Infralitorales y Circalitorales: (1.99208368 2.00000000)
Posidonia: (1.81974340 1.97873009)
Arena y Fondo Detritico: (1.92795467 1.99999999)

Pair Separation (least to most):

Posidonia and Arena y Fondo Detritico - 1.73362781
Posidonia and Cymodocea - 1.81974340
Rocas Infralitorales y Circalitorales and Posidonia - 1.92789454
Arena y Fondo Detritico and Cymodocea - 1.92795467
Rocas Infralitorales y Circalitorales and Arena y Fondo Detritico - 1.95928716
Rocas Infralitorales y Circalitorales and Cymodocea - 1.99208368

```

Figura 4.13. Índices de separabilidad entre clases.

Analizando los valores, vemos que por lo general son bastante buenos, con índices JM muy cercanos a 2. Observando que, como veremos posteriormente en los mapas, las clases con peor separabilidad son la Posidonia con la Arena y Fondo Detrítico, ya que presentan gran confusión sobre todo a profundidades muy elevadas, donde se oscurece notablemente el fondo. También destacar la delicada diferenciación entre ambos tipos de vegetación (Cymodocea y Posidonia) ya que dicha separabilidad depende de un parámetro tan delicado como su densidad, como se comentó recientemente.

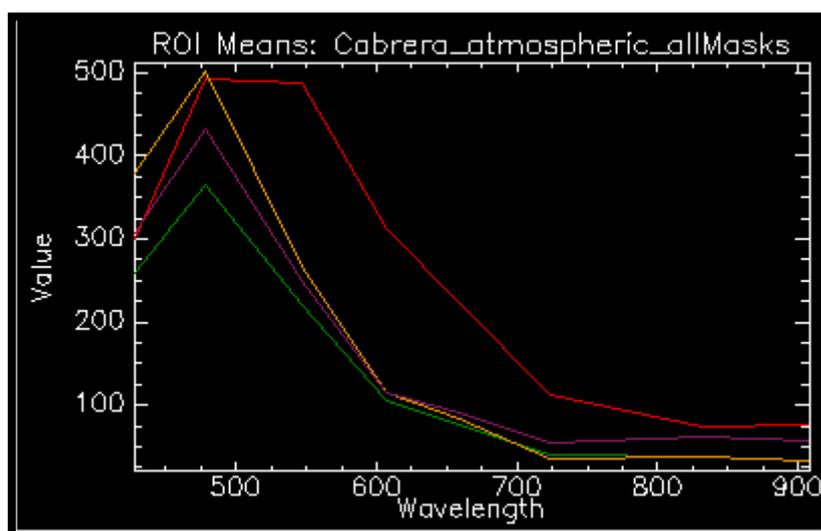


Figura 4.14. Firmas espectrales de cada clase.

En cuanto a las firmas espectrales se observa gran similitud entre ellas producto de la contribución de la columna de agua, cuya eliminación no se aborda en este Trabajo de Fin de Grado.

#### 4.5.4. Análisis a nivel de algoritmo de clasificación

En este apartado se analiza la precisión de la clasificación realizada en la imagen en función del algoritmo de clasificación empleado. En la Tabla 4.7. se puede ver la fiabilidad de cada mapa, así como el índice kappa. Se aprecia que tanto SVM como ML proporcionan resultado satisfactorio.

Tabla 4.7. Fiabilidad y coeficiente kappa de cada clasificador empleado.

<b>Imagen</b>	<b>ML</b>	<b>SAM</b>	<b>SVM</b>
<i>WorldView-2 (8)</i>	98.0299% (0.8799)	6.4400% (0.0611)	99.0554% (0.9422)

En la Figura 4.15. puede observarse los resultados obtenidos al emplear cada algoritmo por separado usando las mismas regiones de entrenamiento y evaluación. En ellas se evidencia la fiabilidad mostrada en la tabla anterior, siendo el clasificador SVM el que genera el mapa más preciso, aunque tiende a detectar con menor precisión la Cymodocea en zonas de agua profunda. Por otro lado, en las Figuras 4.16 y 4.17., se comparan los resultados con el mapa de referencia más reciente y concretando en las dos áreas de mayor interés por su variabilidad en el fondo marino. Para una correcta interpretación del mapa proporcionado por el IEO se asigna: verde claro y verde oscuro para la Posidonia, amarillo y pastel para la arena, gris para la roca y el verde oliva para la Cymodocea.

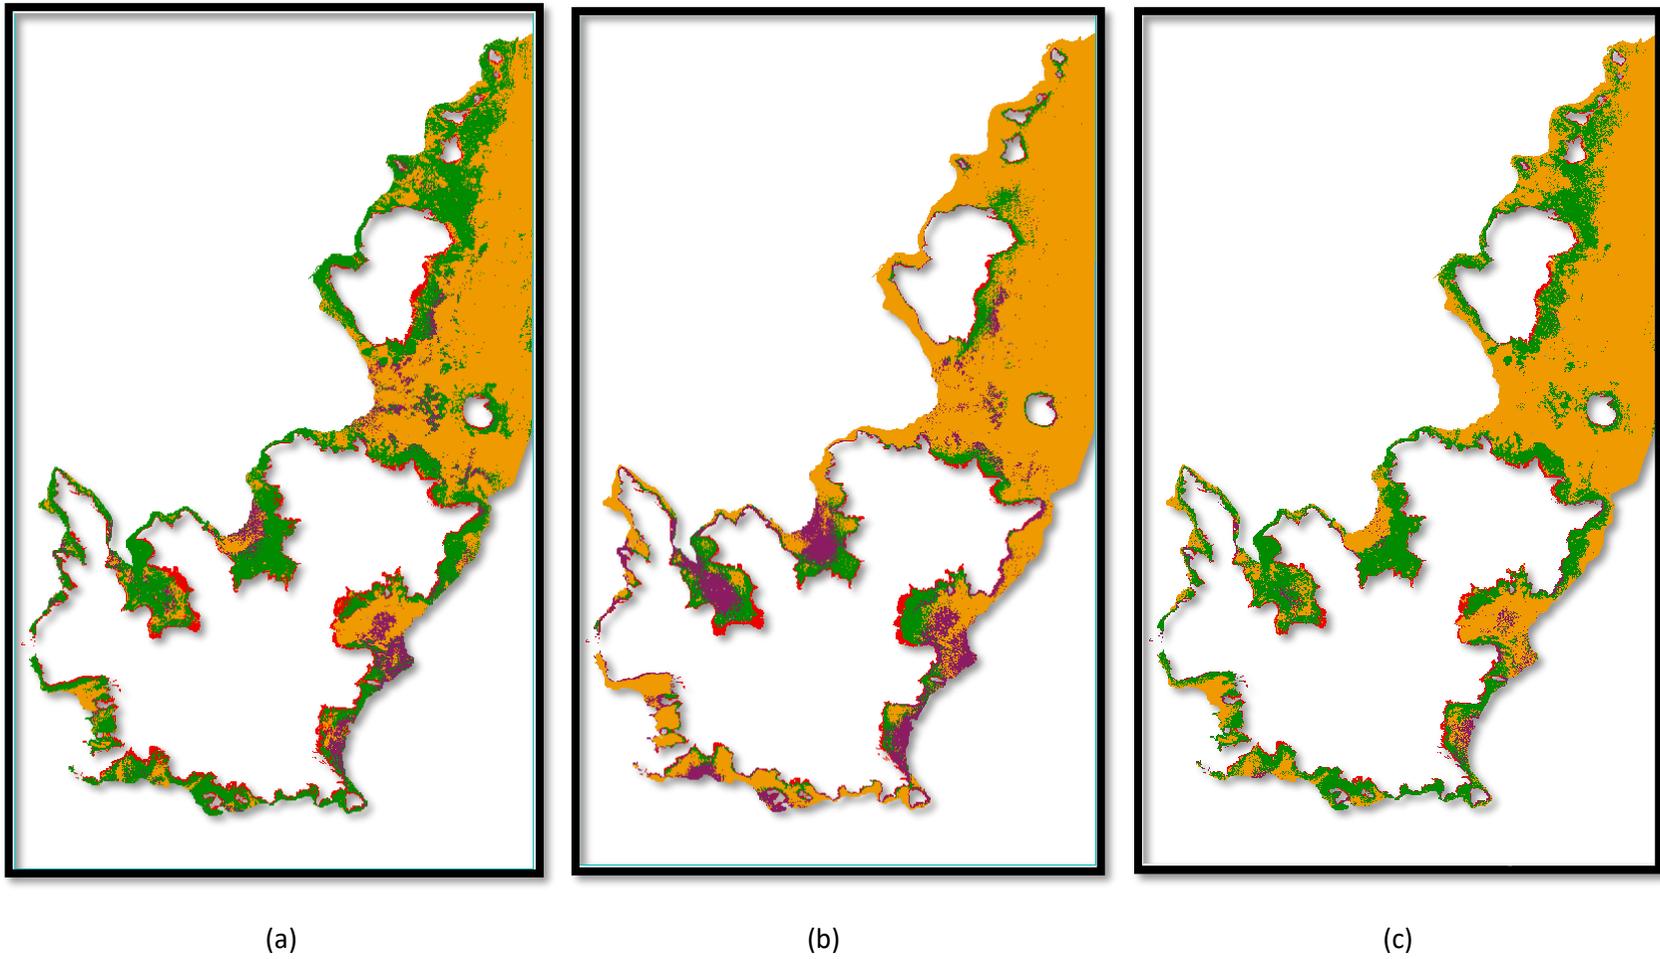
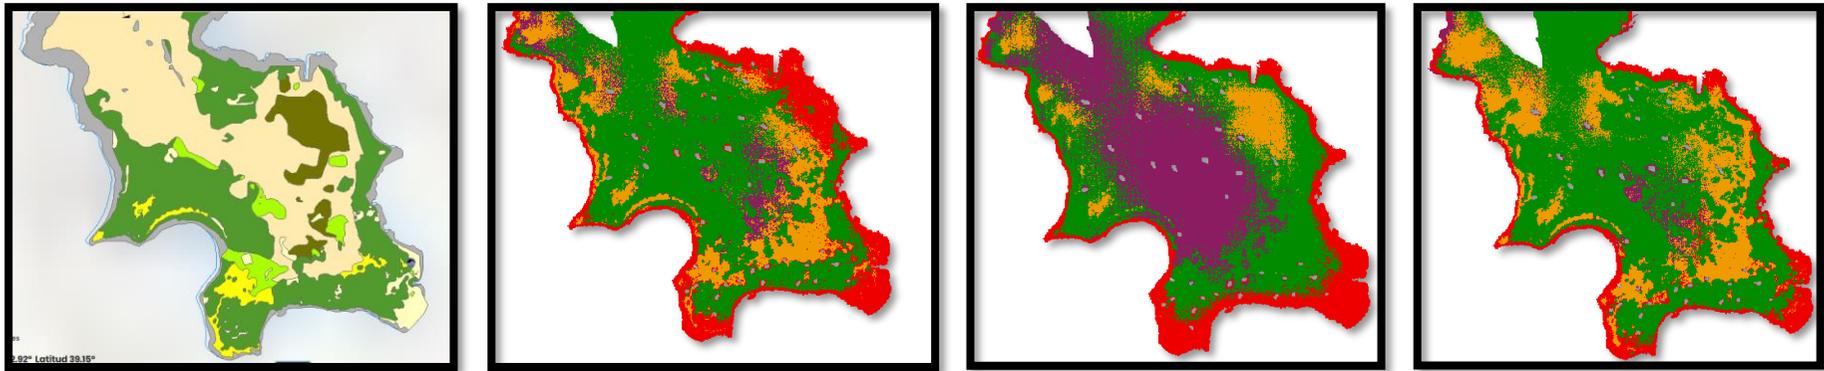
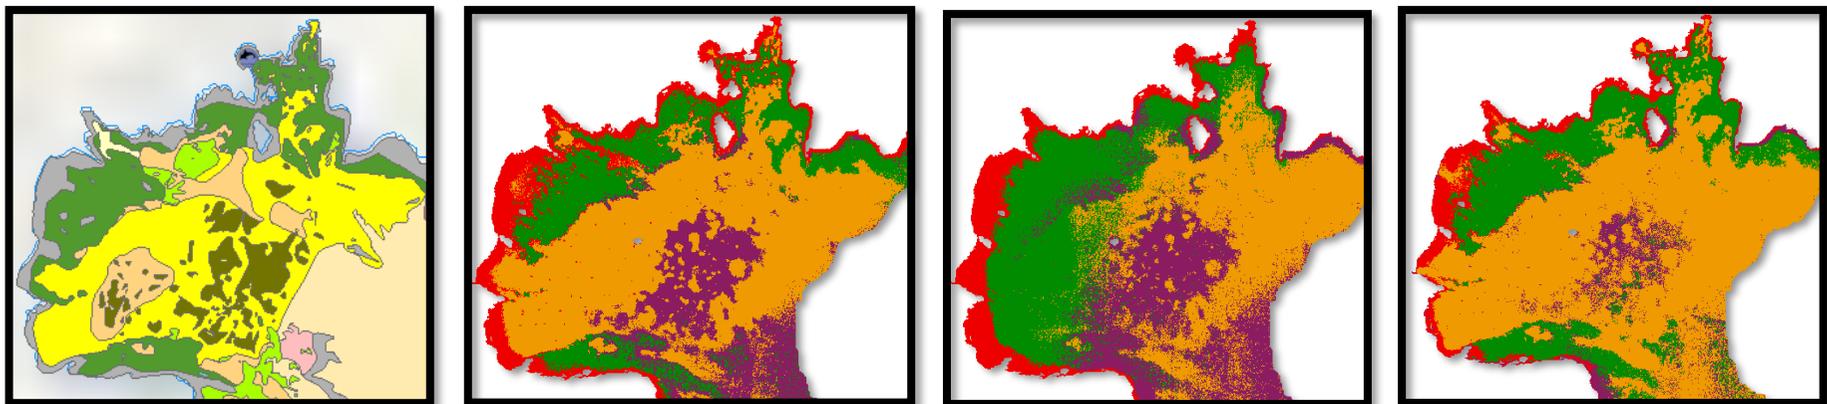


Figura 4.15. Resultados de la clasificación: (a) Maximun Likelihood. (b) Spectral Angle Mapper (c) Support Vector Machine.



(a) (b) (c) (d)

Figura 4.16. Comparativa de la cartografía en la zona del Puerto entre: (a) mapa IEO (2011) [22], (b) mapa ML, (c) mapa SAM y (d) mapa SVM.



(a) (b) (c) (d)

Figura 4.17. Comparativa de la cartografía en la zona de La Olla entre: (a) mapa IEO (2011) [22], (b) mapa ML, (c) mapa SAM y (d) mapa SVM.

#### 4.5.5. Análisis a nivel de clases

Este análisis se realiza a través de la matriz de confusión, que nos dice en qué clases se están cometiendo errores de clasificación. Por ello, generamos una matriz para cada uno de los algoritmos, relacionando las clases identificadas por cada algoritmo de clasificación con las ROIs de evaluación, y así podemos apreciar de forma numérica el grado de coincidencia.

Tabla 4.8. Matriz de confusión para el clasificador ML.

Class	Ground Truth (Percent)					
	Otros	Posidonia	TesCymodocea	TesArena y Fondo	Rocas	Infrali
Unclassified	0.00	0.00	0.00	0.00	0.00	0.00
Otros	100.00	0.00	0.00	0.00	0.00	0.00
Posidonia	0.00	92.92	0.00	19.32	5.36	
Cymodocea	0.00	3.86	100.00	9.47	0.00	
Arena y Fondo	0.00	0.64	0.00	70.43	2.30	
Rocas Infrali	0.00	2.58	0.00	0.78	92.34	
Total	100.00	100.00	100.00	100.00	100.00	

Tabla 4.9. Matriz de confusión para el clasificador SAM.

Class	Ground Truth (Percent)					
	Otros	Posidonia	TesCymodocea	TesArena y Fondo	Rocas	Infrali
Unclassified	100.00	0.00	0.00	0.00	0.00	0.00
Otros	0.00	0.00	0.00	0.00	0.00	0.00
Posidonia	0.00	37.77	2.94	6.79	5.36	
Cymodocea	0.00	23.39	92.65	12.31	3.83	
Arena y Fondo	0.00	35.19	4.41	79.79	0.00	
Rocas Infrali	0.00	3.65	0.00	1.11	90.80	
Total	100.00	100.00	100.00	100.00	100.00	

Tabla 4.10. Matriz de confusión para el clasificador SVM.

Class	Ground Truth (Percent)					
	Otros	Posidonia	TesCymodocea	TesArena y Fondo	Rocas	Infrali
Unclassified	0.00	0.00	0.00	0.00	0.00	0.00
Otros	100.00	0.00	0.00	0.00	0.00	0.00
Posidonia	0.00	96.14	13.24	7.80	5.75	
Cymodocea	0.00	0.00	48.53	2.67	6.51	
Arena y Fondo	0.00	3.22	38.24	89.20	0.38	
Rocas Infrali	0.00	0.64	0.00	0.33	87.36	
Total	100.00	100.00	100.00	100.00	100.00	

Destacar que en el clasificador ML (Tabla 4.8.), la peor precisión la consigue la Arena y Fondo Detrítico con un 70.43% de coincidencia, confundiéndose bastante con la Posidonia, aunque probablemente en aguas profundas como se comentó con anterioridad. También se aprecia el 100% de coincidencia de la Cymodocea, pues el ML sobreestima esta clase, sobre todo en aguas más profundas.

Por otro lado, el clasificador SAM (Tabla 4.9.) es el peor de todos. Vemos como es casi incapaz de diferenciar la Posidonia de la Cymodocea y de la Arena y Fondo Detrítico. También vuelve a ser la Cymodocea la que mejor se adapta a sus valores de entrenamiento.

Por último, el clasificador SVM (Tabla 4.10.). Alcanza precisiones altas en general, siendo el porcentaje de coincidencia más alto para la Posidonia, con un 96.14%. Sin embargo, a diferencia de los anteriores, es la Cymodocea la que presenta mayor dificultad a la hora de separarla con respecto a las demás clases, confundiéndose sobre todo con la Arena y Fondo Detrítico,

probablemente debido a la poca densidad de esta fanerógama lo que provoca una mezcla de contribuciones debida al sustrato.

#### 4.5.6. Cartografía del fondo costero del Parque Nacional de Cabrera

Una vez analizados todos los algoritmos, se selecciona la imagen SVM al alcanzar el mejor resultado de fiabilidad global en su clasificación. Entonces, podemos obtener nuestra cartografía definitiva del fondo costero del Parque Nacional de Cabrera. Asimismo, nos permite comparar este mapa generado con la imagen original del WV2 en la Figura 4.18.

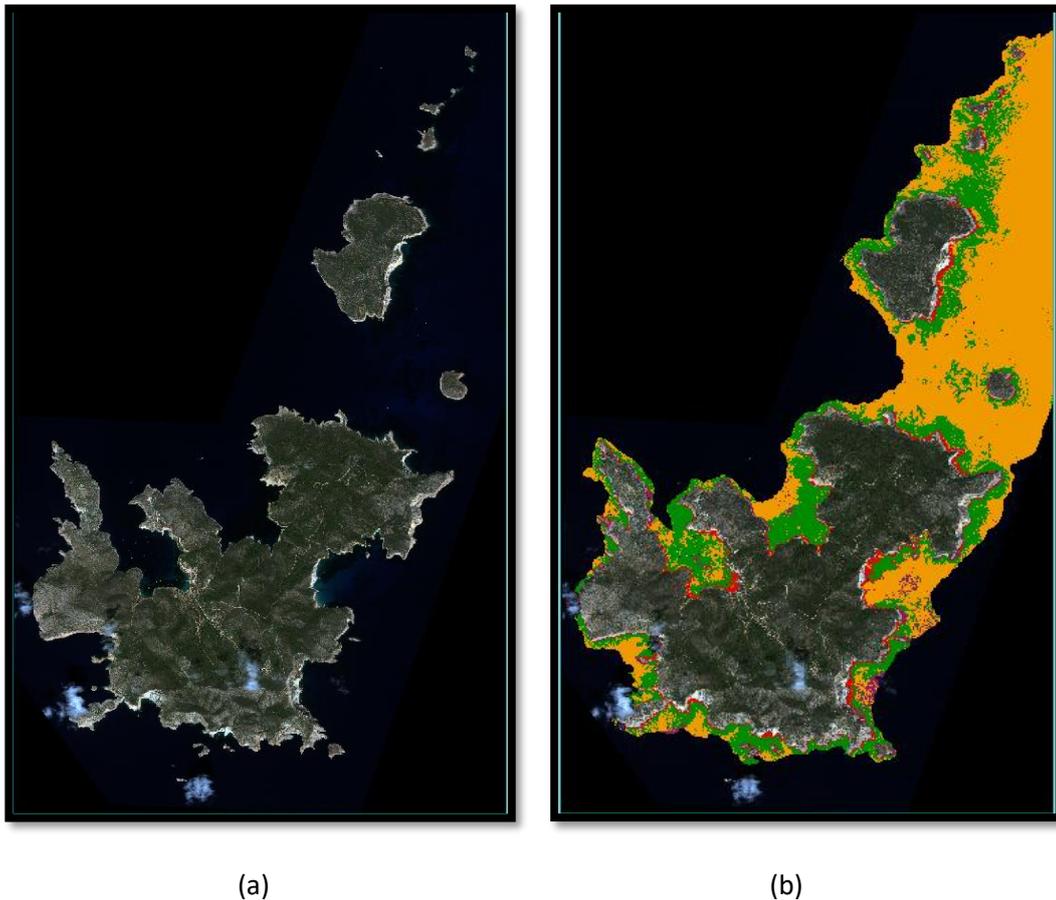
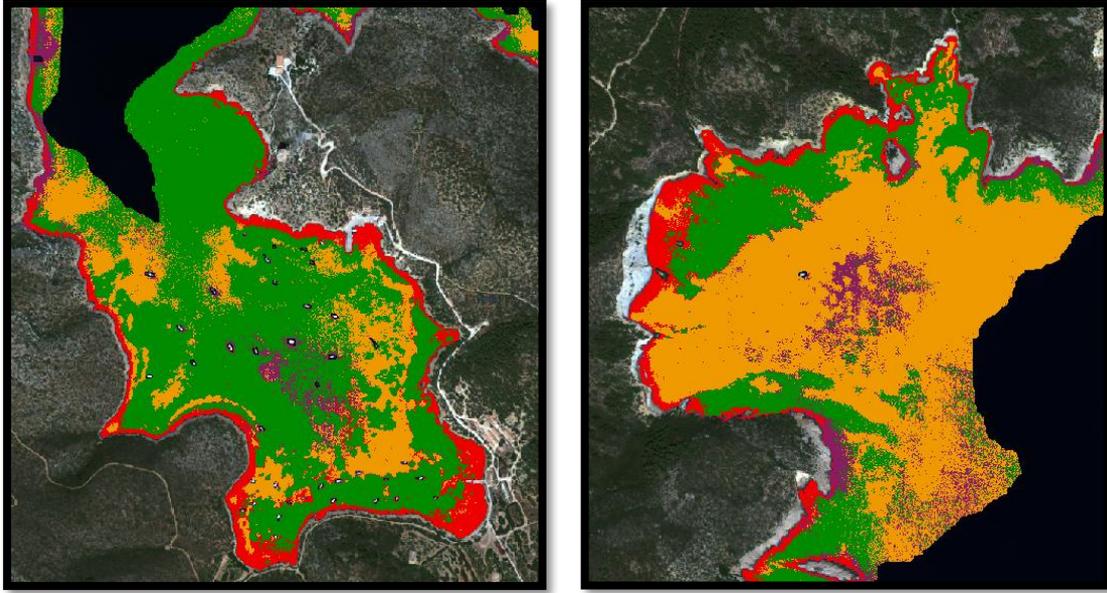


Figura 4.18. Comparativa de imágenes del PN Cabrera: (a) Imagen procedente del WV2 y (b) cartografía temática.

En la Figura 4.19. se puede observar, de forma más específica, la cartografía en las dos zonas de mayor interés del Parque Nacional, el Puerto y la Olla.



(a)

(b)

Figura 4.19. Cartografía marina PN Cabrera: (a) Zona del Port (Puerto) y (b) zona de la Olla.

Para terminar, presentamos una tabla con la superficie que ocupa cada clase en el Parque Nacional.

Tabla 4.11. Inventario de la ocupación del fondo marino en el PN Cabrera.

Clases/Categoría	Superficie (m <sup>2</sup> )	% total
Rocas Infralitorales y Circalitorales	540.308	4,123
Arenas y Fondo Detrítico	8.003.616	61,074
Posidonia	4.156.432	31,717
Cymodocea	404.440	3,086

Ya que la clase "Otros" corresponde al 80% de la imagen, consideraremos el tanto por ciento de cada clase sobre el 20% de superficie restante. Es decir, los porcentajes de la Tabla 4.11. hacen referencia solamente a la superficie subacuática cartografiada.

---

## Capítulo 5

# **GENERACIÓN DEL MAPA DEL FONDO COSTERO MEDIANTE IMAGEN DRON**

---



El capítulo que a continuación se describe aborda la segunda parte de este Trabajo Fin de Grado. En él, se va a estudiar, utilizar y analizar una nueva tecnología que está en pleno desarrollo todavía en el ámbito de la teledetección. Se trata de la integración de sensores hiperspectrales en drones, ya que debido a que poseen gran número de bandas ofreciendo gran resolución hiperspectral. También como consiguen mayor proximidad respecto a la zona de estudio a la hora de capturar las imágenes, ofreciendo con ello alta resolución espacial, se plantea como una buena alternativa a la teledetección por satélite. Pero, como se verá, no va a resultar tan bueno como en principio podría esperarse, sobre todo en medios subacuáticos, que es el que nos concierne.

### 5.1. Datos

Para realizar el estudio del fondo costero mediante dron, se utilizó una imagen captada durante la Campaña de adquisición de imágenes Hiperspectrales de Ultra alta resolución espacial mediante dron en el Parque Nacional Cabrera. La localización se limita a la zona costera del Puerto, y se obtuvo el 18 de septiembre de 2018, durante un proceso de captación realizado alrededor de las 14:00 horas, y que podemos localizar en la Figura 5.1.

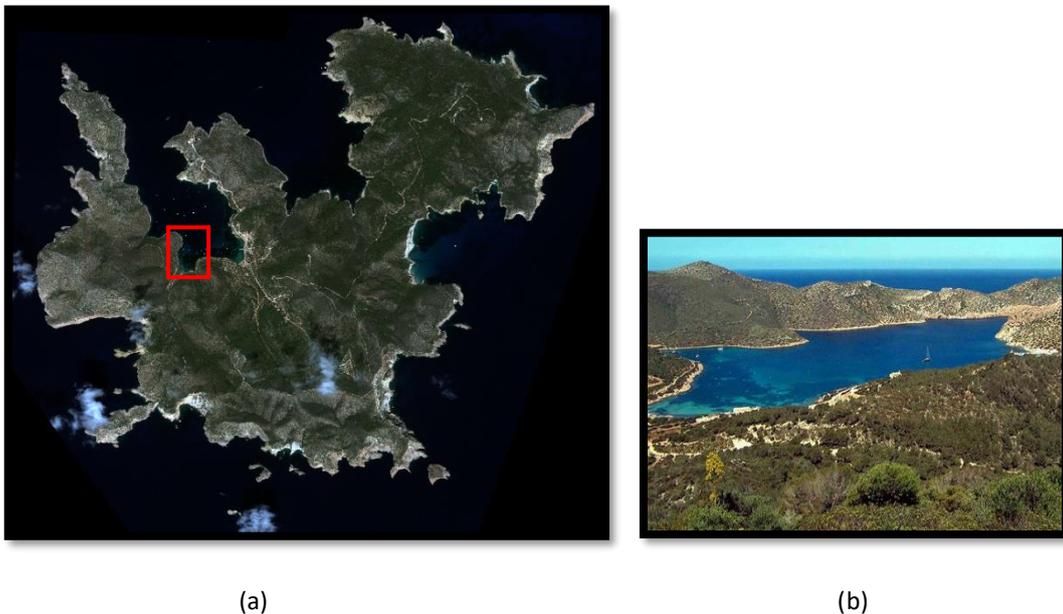


Figura 5.1. (a) Superficie de interés para el estudio mediante dron e (b) imagen de la zona el día de la captación.

Dicha localización (Figura 5.1.) fue una de las elegidas como zona de interés en el Parque Nacional en el momento de realizar la campaña debido a la presencia de diversas especies vegetales subacuáticas y a la claridad de sus aguas. Como se comenta, pertenece a la zona del Puerto y abarca 300.000 metros cuadrados de superficie (0.3 Km<sup>2</sup>). El producto proporcionado es una imagen ortorectificada con resolución espacial de 10cm x 10cm, y proyección UTM (Figura 5.2.). Además, tiene resolución espectral de 150 canales, que barren desde los 400nm hasta los 1000nm, con un ancho de banda por canal de 4nm. También se adquirieron datos de irradiancia solar durante el vuelo para la obtención de la reflectividad y se hizo uso de batimetrías para la ortorectificación respecto al fondo costero [22].

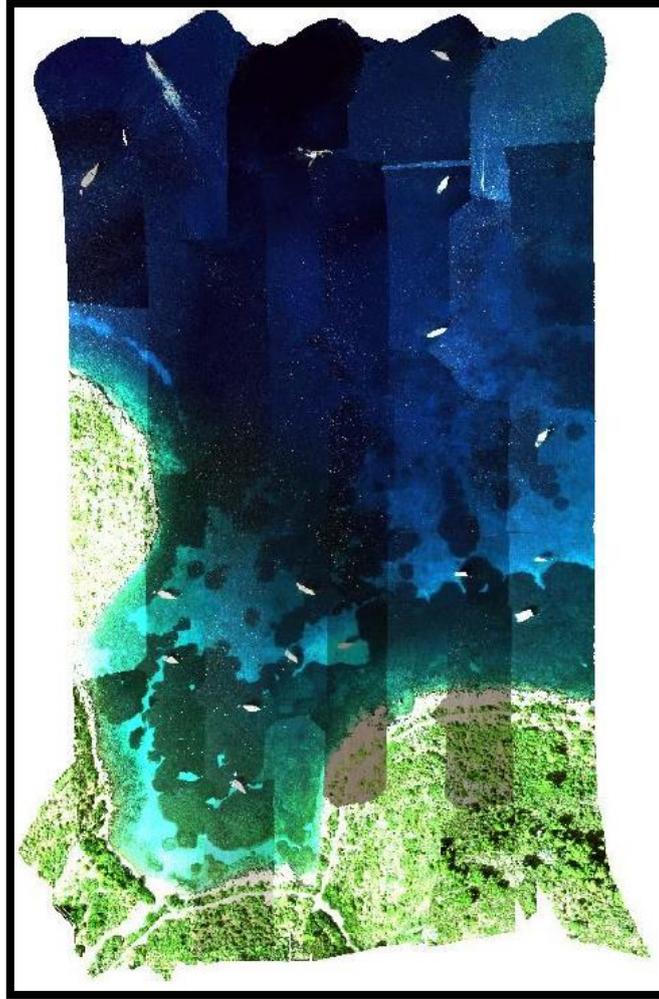


Figura 5.2. Imagen dron en color natural.

A continuación, se indican los diferentes procesados de los datos para la obtención de la imagen.

## 5.2. Preprocesados Dron

### 5.2.1. Procesado radiométrico y uso de batimetría de alta resolución

Gracias a que se fueron almacenando los valores de irradiancia por el sistema durante la captación, se utilizaron posteriormente para el cálculo de la reflectividad mediante la conversión de los valores digitales a radiancia.

También fue necesario realizar un correregistro adecuado del fondo costero, el cual resulta de alto interés en el proyecto. Por lo que se utilizó una batimetría sónica de alta resolución para la ortorectificación de los diferentes hipercubos que forman parte de la imagen final generada [23].

### 5.2.2. Procesado Geométrico, correregistro de hipercubos y mosaicado

El resultado obtenido en el procesado radiométrico requiere de ser ortorectificado, debido a que se mantiene la proyección de adquisición obtenida por el dron. Para ello durante la obtención del hipercubo se obtuvo información de posición del dron mediante sistema GPS y de apuntamiento de la cámara mediante IMU. Finalmente, a través de un modelo geométrico, y mediante la utilización de la batimetría de alta resolución, fue posible ortorectificar la imagen

obtenida en una proyección UTM. A continuación, el corrección de las imágenes se realizó mediante una simple transformación afín debido a la imposibilidad de obtener buenos puntos de control en el fondo costero [23].

Una vez se obtuvo cada hipercono de reflectividad ortorectificado y corregido, el siguiente paso fue generar un mosaico a partir de todas las pequeñas imágenes obtenidas por el dron en la zona de interés.

Por último, dado los movimientos de la plataforma, debido al viento, en ocasiones se generan vibraciones y desplazamientos inesperados del apuntamiento de la cámara. Este hecho genera que existan apuntamientos anómalos de ciertas líneas de la imagen, pequeños saltos de datos y también que los movimientos en el apuntamiento produzcan pequeños huecos entre pase y pase del sensor. Para eliminar estos errores se hace uso de técnicas que permiten rellenar esta ausencia de datos mediante la información del entorno [23].

### 5.2.3. Enmascaramiento

Aplicadas todas las correcciones, seguidamente se generan y aplican las respectivas máscaras para eliminar toda información de la imagen que no sea agua. Entonces, haciendo uso de las ROIs, se genera la máscara y se aplica, obteniendo como resultado la Figura 5.3.

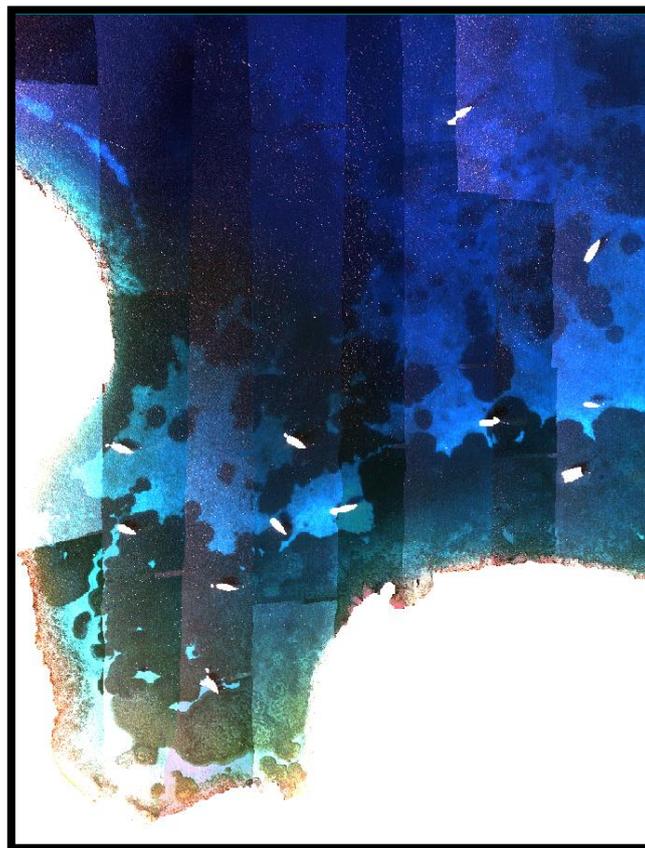


Figura 5.3. Imagen dron tras procesarla.

Como podemos apreciar, la dificultad del procesado de imágenes de ultra alta resolución espacial a bordo de una plataforma a baja altura (120 metros) en entornos costeros, en donde los problemas de refracción no están completamente resueltos, se puede apreciar en algunos solapes entre pases de la imagen mosaicada. Desplazamientos de 1 metro en solapes en el

fondo costero puede apreciarse sobre todo en las zonas de posidonia. Sin embargo, el resultado final de la ortorectificación es bastante satisfactorio.

Por otro lado, en cuanto a la calidad espectral, las imágenes hiperspectrales recogen radiación de anchos de banda muy reducidos, esto implica que la relación señal a ruido suele ser un problema importante en la obtención de dichas imágenes. El sistema utiliza método automático para obtener la mejor cuantificación de los datos según la superficie barrida, sin embargo, esto puede implicar que ciertas superficies de alta reflectividad se saturen. También es necesario tener en cuenta las limitaciones relacionadas con la irradiancia. Para ciertas longitudes de onda (superiores a 850 nm), la irradiancia es muy pequeña lo que produce que la relación señal a ruido sea mínima esto causa que la reflectividad obtenida en el rango de los 900-1000 nm sean muy ruidosas. De la misma forma, existe una longitud de onda de 760 nm, en donde, aunque el sol proporciona irradiancia aceptable, la atmósfera introduce una elevadísima absorción debido a que es la longitud de onda de absorción del oxígeno molecular. Por este motivo, es posible detectar picos que rompen la continuidad del espectro en ese punto. Lo más normal en el procesado de datos es no utilizar esta longitud de onda.

Es necesario incidir que la imagen se ha generado mediante mosaicado de múltiples hipercubos obtenidos en un recorrido zigzag, por este motivo existen pequeñas variaciones en la reflectividad entre los pases realizados en un sentido y el contrario. Esto se debe a la variación del ángulo de acimut entre la luz incidente y el ángulo de visión, lo que ocasiona pequeñas variaciones de reflectividad no contempladas en los algoritmos de calibración radiométrica y de obtención de reflectividad superficial. De la misma manera, dentro de los hipercubos se producen pequeñas variaciones en la reflectividad debido a los diferentes ángulos de visión, siendo mayores en los extremos del hipercubo.

### 5.3. Clasificación

Una vez ya se trabajó sobre la imagen para que esté en perfecta condición de ser clasificada, se puede avanzar a este apartado.

#### 5.3.1 ROIs de entrenamiento y evaluación

Para las regiones de entrenamiento, se siguió exactamente el mismo criterio y procedimiento que para la imagen del WV2. Como recordatorio, las categorías clasificadas son las siguientes:

Tabla 5.1. Tabla de clases por colores asignados a la clasificación de la cartografía marina para imagen dron.

Clases/Categorías	Valor RGB	Color
Rocas Infralitorales y Circalitorales	(240, 0, 0)	
Arenas y Fondo Detrítico	(240, 150, 0)	
Posidonia	(0, 153, 0)	
Otros	(0, 255, 255)	

Como se aprecia, en la Tabla 5.1, se ha eliminado la clase “Cymodocea”, ya que no se encuentra en esta región.

Una vez generadas las ROIs de entrenamiento de la misma manera que antes, queda la siguiente distribución:

Tabla 5.2. Número de ROIs de entrenamiento por clases para imagen dron.

Clases/Categorías	ROIs de entrenamiento
Rocas Infralitorales y Circalitorales	21
Arena y Fondo Detrítico	42
Posidonia	39
Otros	5

Seguidamente, se establecen las regiones de interés para la posterior evaluación de la fiabilidad de los resultados. Siguiendo los mismos criterios, se obtuvo:

Tabla 5.3. Número de ROIs de evaluación por clases para la imagen dron.

Clases/Categorías	ROIs de evaluación
Rocas Infralitorales y Circalitorales	37
Arena y Fondo Detrítico	38
Posidonia	42
Otros	5

### 5.3.2. Separabilidad entre clases y firmas espectrales

Al igual que para las ROIs de la imagen WV2, y siguiendo el mismo criterio, en la Figura 5.4. se muestran los índices de separabilidad espectral entre cada una de las parejas de clases e, inmediatamente después, se generan sus firmas espectrales.

```

Input File: Port_Dron_Masks_b1a40
ROI Name: (Jeffries-Matusita, Transformed Divergence)

Posidonia:
  Arena y Fondo Detritico: (1.99802104 2.00000000)
  Rocas Infralitorales y Circalitorales: (1.95633370 1.99995775)

Arena y Fondo Detritico:
  Posidonia: (1.99802104 2.00000000)
  Rocas Infralitorales y Circalitorales: (1.99593526 2.00000000)

Rocas Infralitorales y Circalitorales:
  Posidonia: (1.95633370 1.99995775)
  Arena y Fondo Detritico: (1.99593526 2.00000000)

Pair Separation (least to most):
Posidonia and Rocas Infralitorales y Circalitorales - 1.95633370
Arena y Fondo Detritico and Rocas Infralitorales y Circalitorales - 1.99593526
Posidonia and Arena y Fondo Detritico - 1.99802104
  
```

Figura 5.4. Índice de separabilidad entre clases para las ROIs de entrenamiento.

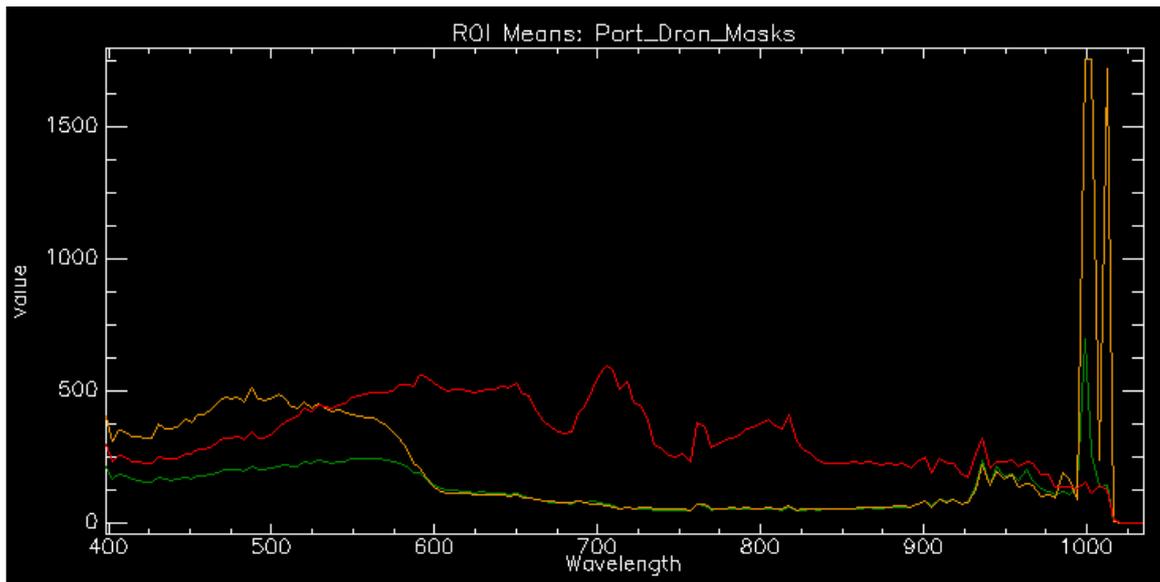


Figura 5.5. Firmas espectrales media de cada clase para las ROIs de entrenamiento.

Analizando los valores, son bastante mejores que en el caso del satélite, siendo la separabilidad más baja de 1.96 (sobre 2) entre la Posidonia y las rocas. Hay que destacar, sobre todo, que en la firma espectral caen los valores en longitudes de onda superiores a 600nm. Incluso, las últimas bandas, más allá de aportar información, lo que hacen es añadir ruido.

### 5.3.3. Análisis a nivel de clasificación

Como la imagen dron tiene 150 bandas, la aplicación de los algoritmos de clasificación se complica sustancialmente. Es por eso por lo que a partir de los resultados de estudio anterior se decidió utilizar solamente el método SVM, ya que la experiencia nos dice que es el más fiable.

Por otro lado, como se ve en la Figura 5.5, también es reseñable que de las 150 bandas que nos ofrece la imagen, tan solo apenas unas 40 realmente nos proporciona información en el agua. De otra forma, para reducir la dimensionalidad espectral, es posible aplicar transformaciones como el Análisis en Componentes Principales (PCA), que realiza una transformación lineal que reorganiza la varianza de cualquier imagen multibanda en un nuevo set de bandas nuevas [24]. Se puede apreciar en la figura 5.6. que, tras aplicar PCA, tan solo hay información útil en las primeras 7-8 bandas, aunque después, para el clasificador, se tome hasta la banda 20 como margen de seguridad. Por ello, se realizaron tres estudios diferentes en función del número de bandas que utilizará el clasificador como información para generar el mapa:

- Tomando las primeras 20 bandas tras PCA.
- Tomando solo las primeras 40 bandas originales.
- Tomando las 150 bandas de la imagen original.

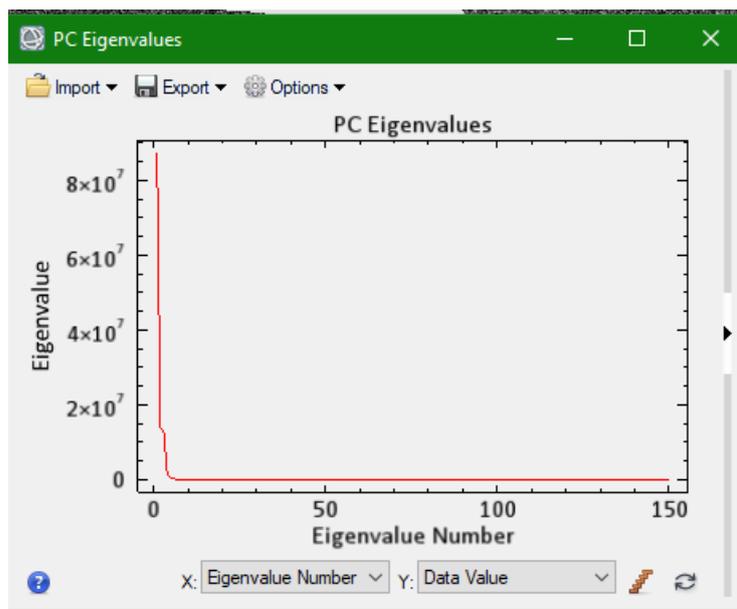


Figura 5.6. Nivel de información por bandas tras PCA.

Entonces, primero, se procedió a analizar la precisión de la clasificación realizada por el algoritmo SVM para cada una de las opciones. Tal y como se hizo en la clasificación de la imagen satélite, se presenta la Tabla 5.4. con la fiabilidad del SVM en cada una de las imágenes, así como su índice kappa.

Tabla 5.4. Fiabilidad y coeficiente kappa del SVM en cada caso.

<i>Imagen</i>	<b>SVM (PCA 20)</b>	<b>SVM (40)</b>	<b>SVM (150)</b>
<i>Pika-L</i>	88.6618% (0.8291)	91.5634% (0.8707)	96.9979% (0.9535)

Como muestra la tabla, obviamente, cuantas más bandas utilizemos para clasificar la imagen, más exacto es el resultado. Aunque el tiempo de computo se incrementa enormemente. Pero cabe destacar que se produce mejora al aumentar las bandas de 40 a 150 a pesar de que las últimas 110 bandas son muy poco útiles en el análisis subacuático.

En las siguientes figuras se pueden observar los resultados obtenidos al aplicar el clasificador SVM en cada uno de los conjuntos de bandas. Podemos confirmar visualmente como el generado por las 150 bandas es más exacto, aunque se parezca mucho al generado a partir de las 40 primeras bandas.

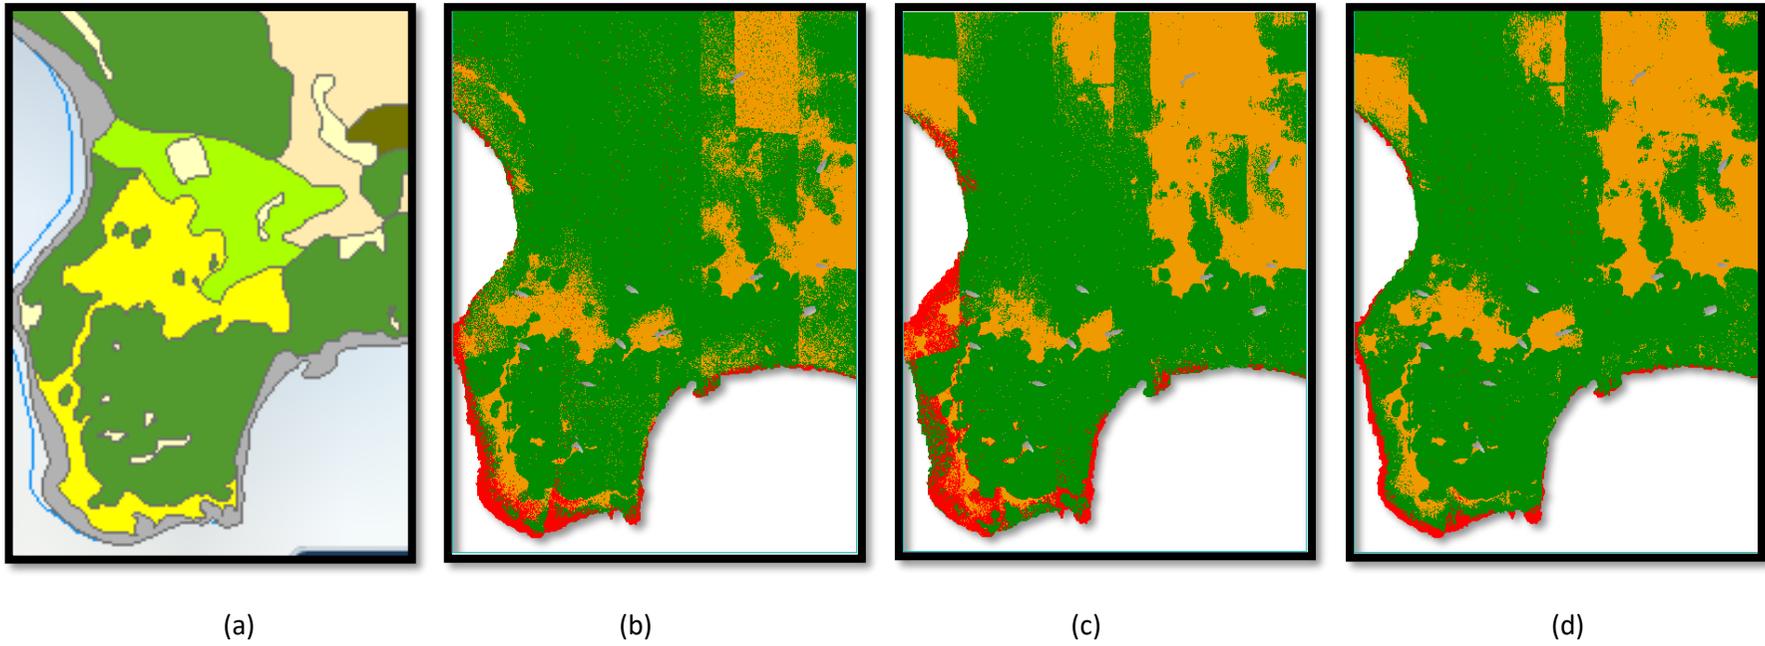


Figura 5.7. (a) Cartografía del IEO [22] y resultados de la clasificación: (b) SVM a primeras 20 bandas tras PCA, (c) SVM a primeras 40 bandas, (d) SVM a las 150 bandas.

Sobre los resultados, se aprecia como las variaciones de iluminación en las diferentes tiras, producto de la diferencia temporal entre tiras en el momento de captación, afectan a la calidad de la clasificación. También, con el PCA y 40 bandas sobreestiman la Posidonia en zona de rocas, aunque hay que tener en cuenta la presencia de algas sobre ellas. Otro detalle es que PCA clasifica bien la zona superior izquierda de la imagen, mientras que las otras dos las clasifica como arena.

#### 5.3.4. Análisis a nivel de clases

Nuevamente, se vuelve a utilizar las ROIs de test para analizar la precisión de cada clase. Para ello, como ya se hizo anteriormente, se genera la matriz de confusión para cada uno de los resultados del SVM y muestra la progresión de errores de asignación de cada una de las clases.

Tabla 5.5. Matriz de confusión para el clasificador SVM en la imagen PCA de 20 bandas.

Class	Ground Truth (Percent)				Total
	Posidonia_2	Arena y Fondo	Rocas Infrali	Otros	
Unclassified	0.00	0.00	0.00	0.00	0.00
Posidonia	96.40	4.45	19.53	0.00	47.34
Arena y Fondo	3.50	54.31	0.15	0.00	12.05
Rocas Infrali	0.10	41.24	80.32	0.00	11.60
Otros	0.00	0.00	0.00	100.00	29.02
Total	100.00	100.00	100.00	100.00	100.00

Tabla 5.6. Matriz de confusión para el clasificador SVM aplicado sobre las primeras 40 bandas.

Class	Ground Truth (Percent)				Total
	Posidonia_2	Arena y Fondo	Rocas Infrali	Otros	
Unclassified	0.00	0.00	0.00	0.00	0.00
Posidonia	96.56	2.66	52.13	0.00	48.56
Arena y Fondo	0.06	80.45	15.12	0.00	16.10
Rocas Infrali	3.39	16.89	32.75	0.00	6.33
Otros	0.00	0.00	0.00	100.00	29.02
Total	100.00	100.00	100.00	100.00	100.00

Tabla 5.7. Matriz de confusión para el clasificador SVM aplicado sobre las 150 bandas.

Class	Ground Truth (Percent)				Total
	Posidonia_2	Arena y Fondo	Rocas Infrali	Otros	
Unclassified	0.00	0.00	0.00	0.00	0.00
Posidonia	99.96	12.02	11.31	0.00	50.09
Arena y Fondo	0.04	87.11	0.00	0.00	16.68
Rocas Infrali	0.00	0.88	88.69	0.00	4.21
Otros	0.00	0.00	0.00	100.00	29.02
Total	100.00	100.00	100.00	100.00	100.00

Como se observa, se confirma la información obtenida de forma visual a través de las Figuras 5.7. Por lo general, la clasificación de la Posidonia es muy buena en cualquiera de las imágenes. De resto, comentar por último, que tomando solo las primeras 40 bandas (hasta los 600nm), como vemos en la Figura 5.5., se recoge una pequeña zona de confusión en el espectro que se refleja en el desajuste observable en la precisión de la clase Rocas Infralitorales y Circalitorales.

#### 5.3.5. Cartografía del fondo costero de la zona del Puerto en el Parque Nacional de Cabrera

Una vez analizados todos los métodos de clasificación, se toma el mapa que mejor resultado obtuvo para presentar nuestra cartografía definitiva y finalizar el estudio. Como se viene comentando, el mejor mapa es el generado por el algoritmo SVM aplicado a las 150 bandas

preprocesadas de la imagen dron de un área reducida en la zona del Puerto del PN Cabrera, y cuyo resultado final se pueden ver en la Figura 5.8.

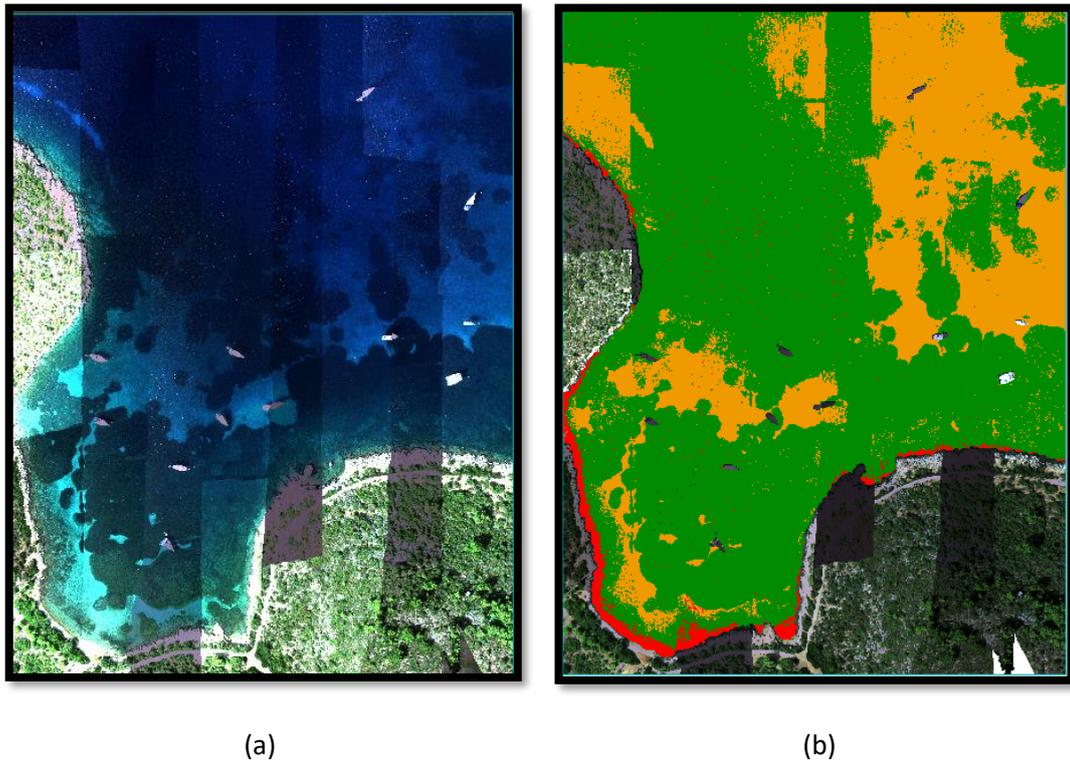


Figura 5.8. Comparativa de imágenes: (a) Imagen dron de una zona del Puerto en el PN Cabrera y (b) cartografía temática.

Por último, como se hizo en el capítulo anterior, se concluye el estudio con la información de ocupación de cada clase en la superficie analizada. Siguiendo el mismo criterio:

Tabla 5.8. Inventario de la ocupación del fondo marino en la zona Puerto del PN Cabrera.

Clases/Categoría	Superficie (m <sup>2</sup> )	% total
Rocas Infralitorales y Circalitorales	3.100,11	2,206
Arenas y Fondo Detrítico	40.575,94	28,873
Posidonia	96.855,36	68,921

---

## Capítulo 6

# **GENERACIÓN DEL MAPA DE CAMBIOS A PARTIR DE IMÁGENES MULTITEMPORALES**

---



Finalmente, como se describe en los objetivos del proyecto, se aprovechó la oportunidad que surgió al poseer dos imágenes, de distinta procedencia, de la misma zona del Parque Nacional de Cabrera captadas en la misma época de dos años distintos (septiembre de 2016 y 2018) para hacer un estudio estricto de cambios.

### 6.1. Comparativa y detección de cambios

Primero, fue necesario recortar la imagen satélite por la misma zona que la imagen dron y con sus mismas dimensiones. Así, permitirá analizar los cambios en la superficie subacuática del fondo costero de esa zona producidos entre septiembre de 2016 y 2018 aplicando una técnica de cambios post-clasificación. En la Figura 6.1 se pueden comparar ambos mapas, donde visualmente se aprecia que las diferencias de iluminación afectan a la calidad del mapa clasificado con los datos del dron. Por tanto, ciertos cambios se deberán a errores en la clasificación y no a cambios reales en el fondo marino.

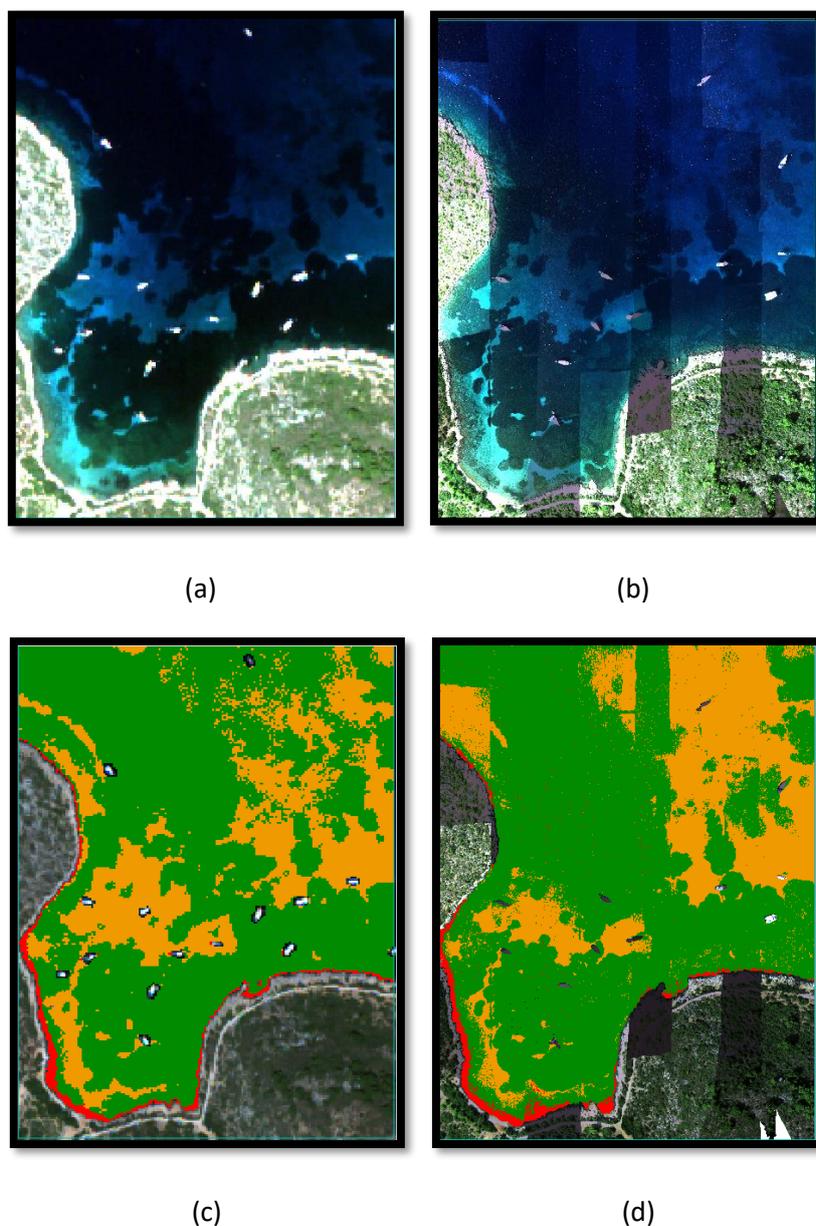


Figura 6.1. Imágenes de la zona Puerto, PN Cabrera: (a) Septiembre 2016 (WV2) y (b) septiembre 2018 (dron), con sus cartografías marina: (c) Septiembre 2016 (WV2) y (d) septiembre 2018 (dron).

A continuación, se procedió a medir las variaciones utilizando la herramienta *Thematic Change Workflow* de ENVI, la cual permite identificar las diferencias entre ambos mapas. Posteriormente, para refinar el resultado del proceso se habilitan dos opciones: suavizado (Smoothing) para eliminar el ruido sal y pimienta, y agregación (Aggregation) para eliminar regiones pequeñas. Para el suavizado se ha empleado un filtro de mayoría con una máscara de 5x5 píxeles, y para la agregación se ha establecido un tamaño mínimo de 4 píxeles, donde las regiones con tamaño de este valor o menor se agregan a una región adyacente mayor. Finalmente, el resultado es el mapa generado de la Figura 6.2.

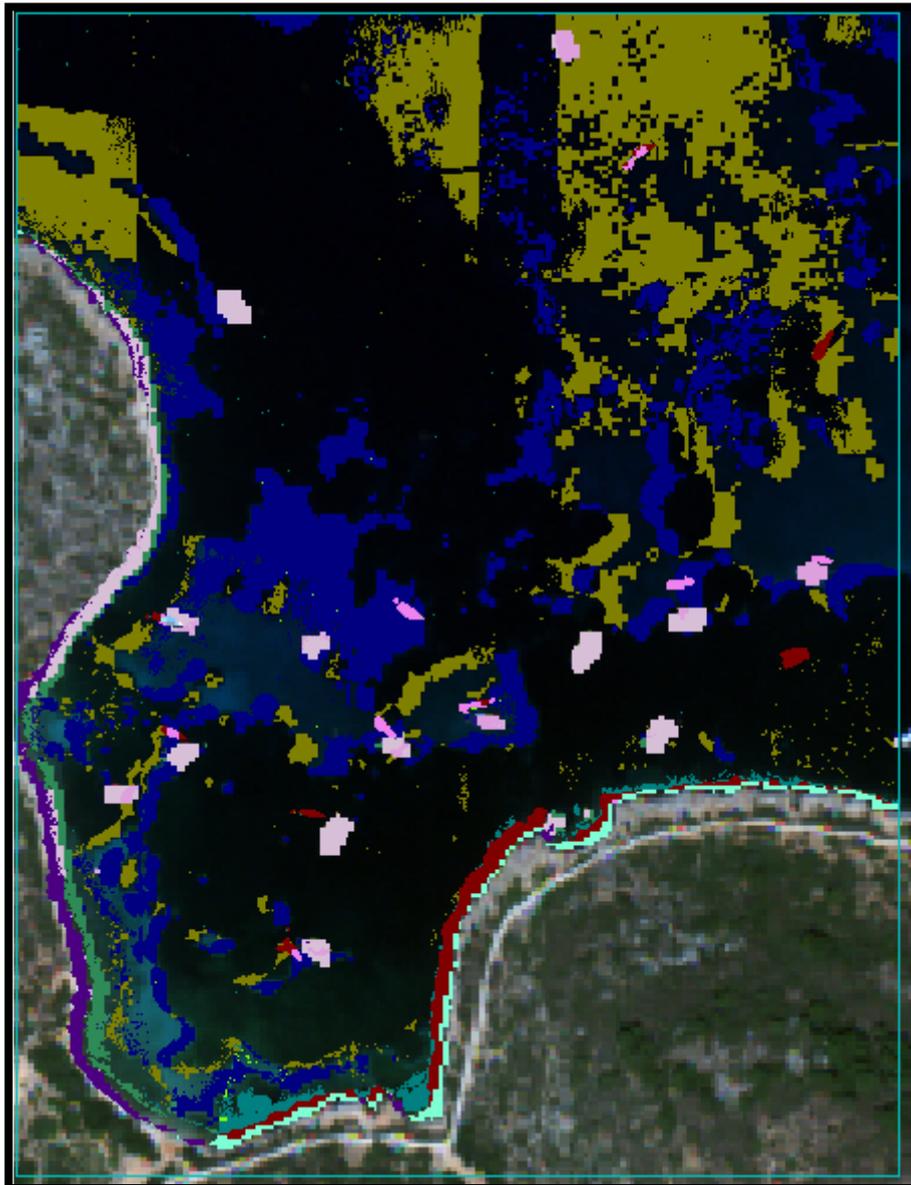


Figura 6.2. Mapa de cambios del fondo marino en la zona Puerto del PN Cabrera ente septiembre de 2016 y septiembre de 2018.

Como se ha mencionado, los desajustes y solapamientos producidos en la imagen dron puede desembocar en clasificaciones de clases en sitios donde realmente no existen, como los

desplazamientos de 1 metro, producidos por solapes, en zonas de posidonia, como ya se aclaró tras los preprocesados. También se aprecian ligeros cambios pegados a la costa debidos a que la correlación geométrica entre las dos imágenes no es perfecta, y al límite de referencia a la hora de aplicar la máscara de tierra en cada caso. Por otro lado, también cerca de la costa, se generan cambios entre Rocas y Posidonia, que tampoco pueden ser del todo fiables ya que, como vimos en las fases de clasificación, las rocas a muy poca profundidad tienen una ligera capa de algas que los algoritmos pueden confundir con la Posidonia por su parecido en la coloración. Obviamos también los cambios detectados por la presencia o ausencia de barcos. Entonces, finalmente, quedan reflejadas dos clases significativas de cambios por su presencia mayoritaria. Éstas son cambios entre la Posidonia y la Arena y fondo Detrítico, o viceversa, como se muestra en la Tabla 6.1.

Tabla 6.1. Leyenda significativa en la detección de cambios.

<b>Categoría de cambio</b>	<b>Color</b>
<b>De Arena y Fondo Detrítico a Posidonia</b>	
<b>De Posidonia a Arena y Fondo Detrítico</b>	

Observando la tendencia del comportamiento de la Posidonia se puede concluir con que la especie está en ligero aumento de su población, sobre todo cerca de la costa, pero a partir de determinada profundidad, por el contrario, se observa que hay una pequeña pérdida de vegetación. Siendo comprobable en la Tabla 6.2., donde se muestran la superficie ocupada por ambas categorías en las dos fechas de la misma zona.

Tabla 6.2. Comparativa de la ocupación de cada categoría en las dos fechas.

<b>Clases/Categoría</b>	<b>Superficie (m<sup>2</sup>) en 2016</b>	<b>Superficie (m<sup>2</sup>) en 2018</b>
<b>Arenas y Fondo Detrítico</b>	38.544	40.575,94
<b>Posidonia</b>	99.512	96.855,36

En cualquier caso es importante destacar que para un análisis de cambios más fiable, además de realizarse la captación de los datos en la misma fecha, es necesario utilizar la misma plataforma, así como regiones de entrenamiento en zonas estables.



---

# Capítulo 7

## **CONCLUSIONES Y LÍNEAS FUTURAS**

---



En este capítulo final se realizará una revisión de los objetivos propuestos inicialmente para valorar la ejecución del trabajo realizado y se presentarán las líneas futuras para un posible avance sobre este estudio.

### 7.1. Revisión de los objetivos

Una vez realizada la cartografía del fondo costero del Parque Nacional Cabrera, se pretende analizar el cumplimiento de los objetivos fijados al inicio de este TFG, así como las tareas realizadas para su consecución. Estos son:

- Se han estudiado las distintas características de las tecnologías multiespectral e hiperespectral y, especialmente, su dificultad a la hora de aplicarse en medios acuáticos. Por ello, se estudió con precisión las diferentes respuestas, en las diferentes bandas, de ambas tecnologías para ser más eficientes en el momento de extracción de información de la imagen.
- Se han estudiado los distintos procesos previos a la clasificación de la imagen con el objetivo de poner en práctica aquellos cuyas soluciones nos fueran de mayor utilidad nuestro estudio.
- Se han analizado los pasos a seguir para ejecutar adecuadamente el proceso de clasificación digital de imágenes. Básicamente, se ha analizado la cartografía existente, se han identificado las clases de interés, se han generado regiones de entrenamiento, se han estudiado y aplicado distintos algoritmos de clasificación (Maximun Likelihood, Spectral Angle Mapper, Support Vector Machine) y se ha evaluado la precisión del mapa generado etiquetando nuevas regiones de la imagen.
- Se han generado mapas temáticos del fondo costero del Parque Nacional Cabrera empleando dos tecnologías diferentes, evaluando su fiabilidad y la de cada clase mediante matrices de confusión, y se ha generado un inventario de la ocupación del fondo marino en ambas situaciones.
- Se ha progresado en el estudio de la tecnología dron hiperespectral para la captación de imágenes remotas y se ha analizado las ventajas e inconvenientes que ésta aporta respecto a la utilización de datos multiespectrales satelitales.
- Se ha realizado un seguimiento de la Posidonia, mediante el estudio y aplicación de técnicas de detección de cambios, durante el periodo desde septiembre de 2016 a septiembre de 2018.

### 7.2. Análisis de resultados

A raíz de los resultados obtenidos a lo largo de este TFG, se han extraído las siguientes conclusiones:

- En primer lugar, se ha evidenciado que, de entre los algoritmos clasificadores empleados (ML, SAM, SVM), el que mejores resultados de clasificación logra es el SVM, aunque el clasificador ML, a pesar de su simplicidad, proporciona también resultados adecuados. Con el clasificador SVM se obtienen los porcentajes más elevados de fiabilidad global en cada una de las imágenes utilizadas.
- Por otra parte, se ha comprobado la dificultad que tiene diferenciar diferentes cubiertas debajo del agua. Ya que la columna de agua atenúa rápidamente la radiación y apenas son de utilidad las bandas entorno al azul y el verde. Además, es necesaria bastante precisión a la hora de poder discriminar en la vegetación subacuática especies tan parecidas como la Cymodocea y la Posidonia, o incluso, éstas de las rocas a poca profundidad cubiertas de algas fotófilas.

- A la hora de evaluar la cartografía, a través de el estudio de los resultados mediante la matriz de confusión de las imágenes clasificadas, se ha puesto de manifiesto que la categoría de Posidonia alcanza unos resultados de clasificación superiores al resto. Esto es debido a que en aguas profundas el agua absorbe casi toda la radiancia y la arena tiende a confundirse con la Posidonia, ya que toma una tonalidad suficientemente oscura como para que apenas se distingan. Y, como recién hemos comentado, las rocas también cuestan diferenciarlas de la propia Posidonia por los algoritmos debido a la vegetación que les crece en su superficie muy cerca de la costa.
- Además, se analizó la aplicación de la tecnología dron en medios acuáticos. Se evidenciaron los muchos problemas radiométricos y geométricos que subyacen tras esta tecnología para abordar una superficie relativamente extensa y que impiden una aplicación tan fiable como la del satélite. En cualquier caso, hay que destacar la elevada resolución espacial que proporciona y, en este caso, al usar un sensor hiperespectral, una capacidad superior para discriminar clases similares. En este contexto, es necesario aplicar las técnicas de preprocesado adecuadas para reducir al máximo estos efectos desfavorables y analizar las imperfecciones que resultan en la imagen final.
- Por último, gracias a las técnicas de detección de cambios, se realizó un seguimiento del comportamiento de las distintas cubiertas del fondo costero de un área reducida en la zona del Puerto en el Parque Nacional de Cabrera entre septiembre de 2016 y septiembre de 2018. También pudimos plasmar este cambio de forma más concreta gracias a la realización del inventario del área en cuestión, clasificada por SVM, deduciendo la superficie de fondo marino que ocupa cada categoría. En consecuencia, analizando las dos clases con los cambios más significativos, se ha concluido que, en 2016, la superficie ocupada por la Posidonia en esta zona es de 38.544 m<sup>2</sup> frente a los 40.755 m<sup>2</sup> de 2018. Sin embargo, la arena varió desde 99.512 m<sup>2</sup> en 2016 hasta los 96.855 m<sup>2</sup> dos años más tarde. En línea con las anteriores conclusiones, hay que destacar que los resultados proporcionados no son del todo fiables debido a los problemas geométricos detectados en la imagen dron, así como la falta de una a registración perfecta entre ambas imágenes.

### 7.3. Líneas futuras

Dada la enorme cantidad de utilidades que aporta la teledetección, pueden surgir múltiples líneas futuras a partir de este Trabajo Fin de Grado. Analizando el trabajo realizado y los resultados obtenidos, se proponen los siguientes estudios futuros:

- Modelar la columna de agua para aplicar la corrección correspondiente en ambas imágenes y obtener las firmas espectrales reales de cada cubierta.
- Mejorar los preprocesados aplicados en la tecnología dron.
- Realizar una detección de cambios más fiable utilizando dos imágenes WorldView-2.

---

# Capítulo 8

## **BIBLIOGRAFÍA**

---



## Bibliografía

- [1] Memoria Resumen de los Proyectos Piloto Realizados en el Parque Nacional del Archipiélago de Cabrera. Plan de Seguimiento y Evaluación de la Red de Parques Nacionales. 2005.
- [2] “Proyecto LIFE Posidonia.” [Online] Available: [http://lifeposidonia.caib.es/user/index\\_cs.htm](http://lifeposidonia.caib.es/user/index_cs.htm) [Accessed: 02/03/2019].
- [3] E. Chuvieco, *Teledetección Ambiental. La observación de la Tierra desde el espacio*. Planeta, S.A., 1ª Ed. Actualizada, 2010.
- [4] “Geo Soatial – WorldView-2.” [Online] Available: <http://www.geospacial.com.co/imagenes-de-satelite/worldview-2.html> [Accessed: 14/04/2019].
- [5] “Satellite Imaging Corporation. WorldView-2” [Online] Available: <https://www.satimagingcorp.com/satellite-sensors/worldview-2/> [Accessed: 14/04/2019].
- [6] “Satellite Imaging Corporation. WorldView-2. Spectral Response” [Online] Available: [http://satimagingcorp.s3.amazonaws.com/site/pdf/WV1\\_WV2\\_SpectralResponse.pdf](http://satimagingcorp.s3.amazonaws.com/site/pdf/WV1_WV2_SpectralResponse.pdf) [Accessed: 14/04/2019].
- [7] “DJI. Matrice 600” [Online] Available: <https://www.dji.com/es/matrice600> [Accessed: 21/04/2019].
- [8] “Resonon. Hyperspectral Imaging Cameras” [Online] Available: <https://resonon.com/content/files/ResononHyperspectralCameras.Datasheet-6.pdf> [Accessed: 21/04/2019].
- [9] Richards, J.A. (2013). *Remote sensing digital image análisis* (5ª ed.). Berlin: Springer-Verlag.
- [10] Chávez, J.L. (2010) *Tratamiento digital de imágenes multiespectrales* (2ªed). Mexico D.F.: UNAM.
- [10] “Spectral Angle Mapper Algorithm for Remote Sensing Image Classification” [Online] Available: [http://ijiset.com/v1s4/IJSET\\_V1\\_I4\\_27.pdf](http://ijiset.com/v1s4/IJSET_V1_I4_27.pdf) [Accessed: 24/04/2019].
- [11] “SVM (Support Vector Machine) – Theory.” [Online] Available: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72> [Accessed: 24/04/2019].
- [12] CHAVEZ, Pat S. Image-based atmospheric corrections-revisited and improved. *Photogrammetric engineering and remote sensing*, 1996, vol. 62, no 9, p. 1025-1035.
- [13] MAHINY, Abdolrassoul S.; TURNER, Brian J. A comparison of four common atmospheric correction methods. *Photogrammetric Engineering & Remote Sensing*, 2007, vol. 73, no 4, p.361-368.

- [14] BERNSTEIN, Lawrence S., et al. A new method for atmospheric correction and aerosol optical property retrieval for VIS-SWIR multi-and hyperspectral imaging sensors: QUAC (Quick Atmospheric Correction). SPECTRAL SCIENCES INC BURLINGTON MA, 2005.
- [15] GRUNINGER, John H.; RATKOWSKI, Anthony J.; HOKE, Michael L. The sequential maximum angle convex cone (SMACC) endmember model. En Defense and Security. International Society for Optics and Photonics, 2004. p. 1-14.
- [16] KARPOUZLI, E.; MALTHUS, T. The empirical line method for the atmospheric correction of IKONOS imagery. International Journal of Remote Sensing, 2003, vol. 24, no 5, p. 1143-1150.
- [17] ADLER-GOLDEN, Steven M., et al. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. En SPIE's International Symposium on Optical Science, Engineering, and Instrumentation. International Society for Optics and Photonics, 1999. p. 61-69.
- [18] COOLEY, T., et al. FLAASH, a MODTRAN4-based atmospheric correction algorithm, its application and validation. En Geoscience and Remote Sensing Symposium, 2002. IGARSS'02. 2002 IEEE International. IEEE, 2002. p. 1414-1418.
- [19] RICHTER, Rudolf; SCHLÄPFER, D. Atmospheric/topographic correction for satellite imagery. DLR report DLR-IB, 2005, p. 565-01.
- [20] VERMOTE, E., et al. Second simulation of a satellite signal in the solar spectrum-vector (6SV). 6S User Guide Version, 2006, vol. 3, p. 1-55.
- [21] "EARTHDATA. GIOVANNI" [Online] Available: <https://giovanni.gsfc.nasa.gov/giovanni/> [Accessed: 5/02/2019].
- [22] "IDEO. Instituto Español de Oceanografía" [Online] Available: <http://www.ideo-cabrera.ieo.es/Home> [Accessed: 22/03/2019].
- [23] A. Medina Machín, "Campaña de adquisición de imágenes Hiperespectrales de Ultra alta resolución espacial mediante Dron en Cabrera", Elittoral, LPGC, España, Estudios de Ingeniería Costera y Oceanográfica, 2019.
- [24] "HARRIS Geospatial Solution. Principal Components Analysis." [Online] Available: <https://www.harrisgeospatial.com/docs/PrincipalComponentAnalysis.html> [Accessed: 11/05/2019].





# PLIEGO DE CONDICIONES



En este apartado, se indican las características hardware de los equipos utilizados, así como las herramientas software empleadas en el desarrollo de este Trabajo de Fin de Grado y este documento.

### PC.1. Requisitos hardware

En el desarrollo de este proyecto, se hizo uso de los siguientes equipos:

- Ordenador *Lenovo* modelo *G50-80 80E5* en el que se han ejecutado los diferentes programas con los que se ha realizado el procesamiento de las imágenes, los resultados obtenidos y el desarrollo de la memoria de este Trabajo Fin de Grado.
  - Sus características son las siguientes:
    - Sistema Operativo Windows 10.
    - Procesador Intel® Core™ i7-5500U CPU @2,40GHz 2,40GHz.
    - 8 GB de memoria RAM.
- Impresora *HP* modelo *Deskjet 3050 J610 series* usada para la impresión de la presente memoria.

### PC.2. Requisitos software

Las herramientas software utilizadas en este Trabajo Fin de Grado han sido:

- Sistema operativo Windows 10: Sistema operativo a través del cual se ha realizado el proyecto.
- Microsoft Office 2016: Diferentes programas (*Word, Power Point*) con los que se han elaborado la memoria y síntesis de resultados.
- ENVI 5.1: Programa de procesamiento de imágenes de teledetección usado para procesar y analizar imágenes en tareas como la selección de regiones de interés y la obtención de mapas clasificados, índices de fiabilidad y firmas espectrales.

### PC.3. Imágenes utilizadas

Las imágenes utilizadas para el desarrollo de este proyecto proceden de los sensores:

- Sensor multiespectral WorldView-2.
- Cámara hiperespectral Pika-L.



# PRESUPUESTO



En este apartado se muestra el presupuesto del Trabajo Fin de Grado realizado. Como referencias se ha seguido el procedimiento establecido por el Colegio Oficial de Ingenieros Técnicos de Telecomunicaciones (COITT).

El presupuesto ha sido dividido en los siguientes apartados:

1. Recursos Materiales.
2. Trabajo Tarifado por Tiempo Empleado.
3. Costes de Redacción del Trabajo Fin de Grado.
4. Material Fungible.
5. Derechos de Visado del COITT.
6. Gastos de Tramitación y Envío.
7. Aplicaciones de Impuestos.

### P.1. Recursos materiales

Se consideran recursos materiales al software, hardware e imágenes utilizadas para la realización de este Trabajo Fin de Grado. En este caso han sido:

- Recursos hardware:
  - Ordenador *Lenovo* modelo *G50-80 80E5*, utilizado en el desarrollo del Trabajo

En la tabla P.1 se detalla el coste de estos recursos, estipulando un periodo de amortización de 3 años con uso del mismo de 4 meses en los que ha durado el Trabajo.

*Tabla P.1 Cálculo del coste de recursos hardware.*

<b>Recursos Hardware</b>	<b>Coste</b>	<b>Coste/Mes</b>	<b>Meses</b>	<b>Total</b>
Ordenador Lenovo	695,00 €	19,31 €	4	77,22 €
<b>Total recursos hardware</b>				<b>77,22 €</b>

- Recursos software:
  - Paquete Microsoft Office 16, usado en la elaboración de la memoria
  - Software ENVI 5.1, para analizar las diferentes imágenes

En este caso, el periodo de amortización es de 3 años para el software ENVI y siendo gratuita la licencia de estudiante del paquete Office 2016. Su coste se puede ver en la tabla P.2:

Tabla P.2 Cálculo del coste de recursos software.

Recursos Software	Coste	Coste/Mes	Meses	Total
MS Office 2016	0,00 €	0,00 €	4	0,00 €
ENVI 5.1.	15.816,67 €	439,35 €	4	1.757,40€
<b>Total recursos software</b>				<b>1.757,40€</b>

- Imágenes utilizadas:
  - Imagen WorldView-2
  - Imagen hiperespectral dron

En este caso, el periodo de amortización para las imágenes es de 3 años y su coste se puede ver en la tabla P.3:

Tabla P.3 Cálculo del coste de imágenes.

Imágenes Satelitales	Coste	Coste/Mes	Meses	Total
Imagen WV2	628,00 €	17,44 €	4	69,77 €
Imagen dron	1.500 €	41,66 €	4	166,6 €
<b>Total imágenes</b>				<b>236,37 €</b>

## P.2. Trabajo Tarifado por Tiempo Empleado

El tiempo en horas empleado en el desarrollo de este Trabajo Fin de Grado, ha sido de 300 horas distribuidas en formación, ejecución y redacción necesarias para la ejecución total del mismo. Siguiendo las directrices del COITT, el importe de las horas de trabajo utilizadas se calcula como:

$$H = C_t * 74,88 * H_n + C_t * 96,72 * H_e \quad (P.1)$$

donde:

- $H$  son los honorarios totales por el tiempo dedicado.
- $C_t$  es un factor de corrección función del número de horas trabajadas.
- $H_n$  son las horas normales trabajadas (dentro de la jornada laboral).

- $H_e$  son las horas especiales.

En la realización de este Trabajo se han empleado 300 horas en horario normal y el coeficiente  $C_t$  tiene un valor que depende del número de horas empleadas en función de la tabla P.4:

*Tabla P.4 Factor de corrección en función del número de horas invertidas.*

Horas empleadas	Factor de corrección $C_t$
Hasta 36 horas	1,00
Desde 36 horas a 72 horas	0,90
Desde 72 horas a 108 horas	0,80
Desde 108 horas a 144 horas	0,70
Desde 144 horas a 180 horas	0,65
Desde 180 horas a 360 horas	0,60
Desde 360 horas a 540 horas	0,55

Como el número de horas dedicadas al Trabajo Fin de Grado ha sido 300, el factor de corrección  $C_t$  a aplicar es  $C_t = 0,60$ . Con lo que la ecuación P.1 con el importe por horas de trabajo resulta:

$$H = 0,60 * 74,88 * 300 + 0,60 * 96,72 * 0 = 13.478,40 \text{ €}$$

Por lo que, **los honorarios totales por tiempo dedicado libres de impuestos ascienden a trece mil cuatrocientos setenta y ocho euros con cuarenta céntimos (13.478,40 €).**

### P.3. Costes de Redacción del TFG

El importe asociado a la redacción del Trabajo se calcula siguiendo la expresión P.2:

$$R = 0,07 * P * C_n \quad (P.2)$$

donde:

- $R$  es el presupuesto del proyecto.
- $C_n$  es el coeficiente de ponderación en función del presupuesto.

En tabla P.5 se muestra el presupuesto calculado hasta el momento:

*Tabla P.5 Presupuesto (recursos materiales y tiempo empleado).*

<b>Recursos</b>	<b>Costes</b>
Recursos hardware	77,22 €
Recursos software	1.757,40 €
Imágenes	236,37 €
Trabajo tarifado por tiempo empleado	13.478,40€
<b>Total</b>	<b>15.549,39 €</b>

Hasta el momento, el presupuesto calculado es de 15.549,39 €. Al ser el coeficiente de ponderación para presupuestos menores de 30.050 € definido por el COITT con un valor de 1,99, el coste derivado de la redacción del Trabajo es de:

$$R = 0,07 * 15.549,39 * 1,00 = 1.088,46 \text{ €}$$

Por lo que, **el coste libre de impuestos derivado de la redacción del Trabajo Fin de Grado es de mil ochenta y ocho euros con cuarenta y seis céntimos (1.088,46 €).**

#### P.4. Material Fungible

Además de los recursos hardware y software, en este Trabajo se han empleado otros materiales como folios y tóner de la impresora entre otros, denominados material fungible. En la Tabla P.6 se presentan los costes de estos materiales.

*Tabla P.6 Costes del material fungible.*

<b>Materiales</b>	<b>Costes</b>
Folios	3 €
Tóner de impresora	50 €
Encuadernación	5.50 €
3 CDs	7,50 €
<b>Total</b>	<b>66,00 €</b>

**Los costes de material fungible ascienden a sesenta y seis euros (66,00 €)**

#### P.5. Derechos de Visado del COITT

Los gastos de visado del COITT se tarifican mediante la siguiente expresión P.3:

$$V = 0,006 * P * C_V \quad (P.3)$$

donde:

- $P$  es el presupuesto del proyecto.
- $C_V$  es el coeficiente reductor en función del presupuesto del proyecto.

El presupuesto calculado hasta el momento asciende a la suma de los costes de ejecución material, redacción y material fungible.

$$P = 15.549,39 \text{ €} + 1.088,46 \text{ €} + 66 \text{ €} = 16.703,85 \text{ €}$$

Al ser el coeficiente de ponderación para presupuestos menores de 30.050 €, definido por el COITT con un valor de 1,00, el coste de los derechos de visado del proyecto asciende a la cantidad de:

$$V = 0,006 * 16.703,85 * 1,00 = 100,22 \text{ €}$$

#### P.6. Gastos de Tramitación y Envío

Los gastos de tramitación y envío están fijados en 6,01 €.

#### P.7. Aplicación de Impuestos

Al presupuesto calculado hasta el momento, hay que sumarle el valor del Impuesto General Indirecto Canario (IGIC), como se refleja en la tabla P.7, obteniendo así el presupuesto definitivo.

*Tabla P.7 Costes totales del TFG.*

Descripción	Costes
Recursos materiales	2.070,99 €

Trabajo tarifado por tiempo empleado	13.478,40 €
Redacción del TFG	1.088,46 €
Material Fungible	66 €
Derechos de visado	100,22€
Gastos de tramitación y envío	6,01 €
<b>Subtotal</b>	<b>16.810,08 €</b>
Aplicación de impuestos (IGIC 6.5%)	1.092,65 €
<b>Total de costes</b>	<b>17.902,73 €</b>

El presupuesto total de este Trabajo Fin de Grado asciende a la cantidad de diecisiete mil novecientos dos euros con setenta y tres (17.902,73€).