


ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO FIN DE MÁSTER

Procesado y aplicación de tecnologías multiplataforma para monitorización marina y terrestre

Titulación: Máster Universitario en Ingeniería de
Telecomunicación

Autor: D. Daniel Baute Trujillo

Tutores: D. Francisco Eugenio González

D. Antonio Ramón Mederos Barrera

Fecha: Julio de 2024

RESUMEN

En las Islas Canarias existen diversos espacios naturales protegidos de gran interés científico y económico. Desafortunadamente, la actividad humana directa y el cambio climático degradan notablemente estas regiones de interés. Por ello, la monitorización de estos espacios es necesaria para prevenir y mitigar efectos negativos. Sin embargo, las superficies marinas y terrestres protegidas están poco controladas debido a su difícil acceso. En este aspecto, la teledetección proporciona información valiosa en zonas remotas que facilitan su gestión y conservación. Además, los resultados de teledetección suponen un coste menor en comparación con campañas de campo. A partir de imágenes de teledetección se puede generar multitud de productos como pueden ser mapas de batimetría, hábitats bentónicos y caracterización del suelo. En superficies marinas, la batimetría permite monitorizar la profundidad y las acumulaciones de sedimentos, mientras que los mapas de hábitats bentónicos permiten estudiar la evolución de las especies vegetales del fondo marino. En superficies terrestres, los mapas de caracterización de suelos permiten identificar la vegetación respecto al terreno y controlar su crecimiento o degradación. En este contexto, el objetivo principal de este Trabajo Fin de Máster consiste en estudiar el estado de los litorales y parques nacionales del archipiélago canario mediante el procesado de imágenes multiespectrales e hiperespectrales de El Río, Zona Especial de Conservación (ZEC) “Sebadales de La Graciosa” de la Red Natura 2000, para la obtención de mapas de batimetría y hábitats bentónicos, y el procesado de datos LiDAR e imagen multiespectral del Parque Nacional de Timanfaya para la caracterización del suelo. Para generar los mapas de batimetría se hace uso de la técnica *Machine Learning Subspace* K-NN y el modelo físico empírico sigmoide, mientras que los hábitats bentónicos se clasifican mediante el modelo *Machine Learning* SVM. Finalmente, los mapas de caracterización del suelo se obtienen mediante la clasificación de la nube de puntos LiDAR y la umbralización de los índices de vegetación NDVI y MSAVI2 a partir de la imagen multiespectral.

ABSTRACT

In the Canary Islands there are several protected natural areas of great scientific and economic interest. Unfortunately, direct human activity and climate change are significantly degrading these areas of interest. Therefore, monitoring of these areas is necessary to prevent and mitigate negative effects. However, marine and terrestrial protected areas are poorly monitored due to their difficult accessibility. In this respect, remote sensing provides valuable information in remote areas that facilitates their management and conservation. In addition, remote sensing results are less costly compared to field campaigns. A multitude of products can be generated from remotely sensed images, such as maps of bathymetry, benthic habitats and soil characterisation. On marine surfaces, bathymetry allows monitoring of depth and sediment accumulations, while benthic habitat maps allow the evolution of plant species on the seabed to be studied. On land surfaces, soil characterisation maps allow us to identify the vegetation in relation to the terrain and to control its growth or degradation. In this context, the main objective of this Master's Thesis is to study the state of the coastlines and national parks of the Canary Islands archipelago by processing multispectral and hyperspectral images of El Río, Special Area of Conservation (SAC) "Sebadales de La Graciosa" of the Natura 2000, to obtain maps of bathymetry and benthic habitats, and processing LiDAR data and multispectral images of Timanfaya National Park for soil characterisation. To generate the bathymetry maps, the Machine Learning Subspace K-NN technique and the empirical physical sigmoid model are used, while the benthic habitats are classified using the Machine Learning SVM model. Finally, soil characterisation maps are obtained by LiDAR point cloud classification and thresholding of NDVI and MSAVI2 vegetation indices from the multispectral image.

ÍNDICE DE CONTENIDOS

Índice de Figuras	IX
Índice de Tablas	XIII
Acrónimos.....	XV
Memoria.....	1
Capítulo 1: Introducción.....	3
1.1. Antecedentes	3
1.1.1. Monitorización marina	3
1.1.2. Monitorización terrestre	5
1.2. Objetivos	7
1.3. Peticionario	7
1.4. Organización de la memoria	8
Capítulo 2: Sensores. Preprocesado de imágenes multiplataforma.....	9
2.1. Sensores	9
2.1.1. Sensores satelitales	11
2.1.2. Sensores dron.....	15
2.2. Preprocesado de imágenes multiplataforma.....	18
2.2.1. Georreferenciación	19
2.2.2. Calibración radiométrica	20
2.3. Corrección atmosférica	21
2.4. Resumen.....	22
Capítulo 3: Monitorización marina: Batimetría y Hábitats Bentónicos en el ecosistema de El Río	23
3.1. Preprocesado para aplicaciones marinas.....	26
3.1.1. Máscara de agua	26
3.2. Corrección del brillo solar	27

3.2.1. Resultados	28
3.3. Batimetría.....	30
3.3.1. Modelo basado en sigmoide (SBM)	32
3.3.2. <i>Subspace K-Nearest Neighbors</i> (S-KNN).....	33
3.3.3. Resultados	36
3.4. Hábitats bentónicos	42
3.4.1. Evolución temporal con imágenes Sentinel-2.....	43
3.4.2. <i>Support Vector Machine</i> (SVM)	46
3.4.3. Resultados	47
3.5. Resumen.....	54
Capítulo 4: Monitorización terrestre: caracterización del suelo del Parque Nacional de Timanfaya	57
4.1. Caracterización del suelo con nube de puntos LiDAR.....	60
4.1.1. Preprocesado LiDAR	61
4.1.2. Resultados	62
4.2. Caracterización del suelo con imagen multiespectral de muy alta resolución.....	70
4.2.1. Índice de Vegetación de Diferencia Normalizada (NDVI).....	71
4.2.2. Índice de Vegetación Ajustado al Suelo Modificado (MSAVI2).....	71
4.2.3. Umbralización.....	72
4.2.4. Resultados	73
4.3. Resumen.....	78
Capítulo 5: Conclusiones	81
Bibliografía	85
Pliego de condiciones.....	91
Pliego de condiciones.....	93
PC.1 Condiciones <i>hardware</i>	93
PC.1 Condiciones <i>software</i>	93

Presupuesto	95
Presupuesto	97
P.1. Recursos Humanos	97
P.2. Recursos materiales	99
P.2.1. Recursos <i>Hardware</i>	99
P.2.2. Recursos <i>Software</i>	99
P.3. Redacción del trabajo.....	101
P.5. Derechos de visado del COIT	101
P.6. Gastos de tramitación y envío.....	102
P.7. Coste total del proyecto	102

ÍNDICE DE FIGURAS

Figura 1.1. Batimetría durante y después de la construcción del puerto en la costa de Granadilla, Tenerife [9].	4
Figura 1.2. Mapa de hábitats bénticos de L’Olla, en la Isla de Cabrera [12].	5
Figura 1.3. El Río, parte de la reserva marina entre las islas de Lanzarote y La Graciosa [14].	5
Figura 1.4. <i>Rumex lunaria</i> en el Parque Nacional de Timanfaya, Lanzarote [19].	6
Figura 2.1. Comparativa espectral entre imágenes RGB, multispectrales y hiperespectrales [20].	10
Figura 2.2. Representación visual de los satélites de la misión Sentinel 2.	11
Figura 2.3. Clasificación espectral y por resolución espacial de las bandas del MSI [23].	12
Figura 2.4. Representación visual del satélite WorldView-2.	14
Figura 2.5 Respuesta espectral de las bandas del WorldView-2 [28].	14
Figura 2.6 Sensor hiperespectral Pika L.	15
Figura 2.7. Respuesta espectral Pika L [29].	16
Figura 2.8. Representación del sensor Micasense Dual a bordo de un dron.	16
Figura 2.9. Distribución de las bandas espectrales del Micasense RedEdge Dual y comparación con otros sensores satelitales [30].	17
Figura 2.10. Sensor LiDAR Zenmuse L1.	18
Figura 2.11. Diagrama del preprocesado para imágenes de teledetección.	19
Figura 2.12. Datos crudos de una imagen WV-2 con bandeado exagerado [28].	20
Figura 3.1. El Río desde Lanzarote con La Graciosa de fondo [35].	23
Figura 3.2. Productos de El Río para la monitorización marina: imagen WV-2 del 22/01/2022 (gris), imagen Pika L del 30/10/2021 (amarillo) e imagen Sentinel-2 del 28/11/2022 (azul).	24
Figura 3.3. Esquema general de la metodología para la obtención de mapas de batimetría y hábitats bentónicos.	25
Figura 3.4. Representación gráfica de la corrección del brillo solar mediante el método de Hedley.	28
Figura 3.5. Georreferenciación en imagen WV-2 de El Río: (a) imagen de estudio y referencia superpuestas con los puntos de control resaltados como circunferencias amarillas, (b) imágenes superpuestas tras la georreferenciación.	29
Figura 3.6. Resultados del preprocesado en la imagen WV-2 de El Río: (a) imagen original del 22 de enero de 2022, (b) máscara de agua de la imagen anterior, y (c) calibración radiométrica y corrección atmosférica de la imagen anterior.	29

Figura 3.7. Resultado de la corrección del brillo solar: (a) imagen original Pika L del 30 de octubre de 2021 (b) imagen anterior tras aplicar el método de Hedley.	30
Figura 3.8. Esquema general de la metodología utilizada para la obtención de mapas de batimetría.	32
Figura 3.9. Ejemplo de clasificación KNN con $k = 5$: (a) espacio de características con dos clases, azul y naranja, y un dato de entrada, negro, (b) clasificación del dato de entrada como azul.	34
Figura 3.10. Esquema general de la fase de entrenamiento de un sistema S-KNN.	35
Figura 3.11. Esquema general de la fase de clasificación de un sistema S-KNN.	35
Figura 3.12. Batimetría de referencia en forma de isobatas y resolución de 1m sobre imagen WV-2 de El Río.	37
Figura 3.13. Mapas de batimetría con datos de entrenamiento completos de El Río con imagen satelital WV-2: (a) Modelo SBM, (b) Modelo S-KNN.	38
Figura 3.14. Ajuste del modelo SBM a los datos de la imagen satelital WV-2.	38
Figura 3.15. Mapa de batimetría de El Río con la imagen dron Pika L obtenido mediante: (a) SBM y (b) S-KNN.	40
Figura 3.16. Ajuste del modelo SBM a los datos de la imagen dron Pika L.	40
Figura 3.17. Comparativa de los mapas de batimetría (a) SBM y (b) S-KNN en la zona de vuelo dron.	41
Figura 3.18. Metodología utilizada para la obtención de mapas de hábitats bentónicos.	43
Figura 3.19. Estudio en un mapa de las zonas de sebadal en el Río en los años 1997, 2001 y 2010 [46].	44
Figura 3.20. Estudio temporal de El Río con imágenes Sentinel-2.	45
Figura 3.21. Estudio temporal de El Río, centrado en las zonas de sebadal con imágenes Sentinel-2.	45
Figura 3.22. Clasificación SVM entre dos clases: (a) espacio de características bidimensional con dos clases libres, (b) existen infinitos hiperplanos posibles que separen ambas clases y, (c) se determina el hiperplano óptimo que mantiene el margen máximo entre las clases.	46
Figura 3.23. Clasificación SVM entre dos clases mediante <i>kernel</i> gaussiano: (a) espacio de características con dos clases que no permiten ser separadas linealmente, (b) cambio en el espacio de características mediante <i>kernel</i> gaussiano y división de las clases mediante hiperplano y, (c) vista de la clasificación SVM en el espacio de características original.	47
Figura 3.24. Puntos propuestos y capturados del fondo marino en la zona de El Río.	48
Figura 3.25. ROIs obtenidos del área de estudio de El Río.	49
Figura 3.26. Firmas espectrales de las clases Roca (marrón), Arena (amarillo), Algas (rojo) y Sebadal (verde).	49

Figura 3.27. Clasificación del fondo marino mediante SVM: (a) imagen preprocesada WV-2 de El Río, (b) Mapa de hábitats bentónicos obtenido al clasificar la imagen completa.	50
Figura 3.28. Mapas de hábitats bentónicos: (a) sin la clase Sebadal y, (b) con la clase Sebadal y Arena, únicamente.....	51
Figura 3.29. Zonas de sebadales reales, según ROI: (a) en la imagen preprocesada WV-2, (b) en la clasificación de la imagen completa con SVM y (c) en la clasificación de la clase Sebadal y Arena mediante SVM.....	51
Figura 3.30. Mapa de hábitats bentónicos mediante SVM con la imagen WV-2 de El Río.....	52
Figura 3.31. Estudio de la evolución del sebadal en El Río con la información del mapa de hábitats bentónicos obtenido.	53
Figura 3.32. Mapa de hábitats bentónicos mediante SVM con la imagen Pika L de El Río.	54
Figura 4.1. Parque Nacional de Timanfaya, en la isla de Lanzarote, Canarias.	57
Figura 4.2. Extensión del Parque Nacional de Timanfaya y ubicación del área de estudio.	58
Figura 4.3. Productos de Timanfaya del 02/11/2023 para la monitorización terrestre: (a) nube de puntos LiDAR Zenmuse L1 con coloración RGB, (b) imagen multispectral MicaSense Dual.	59
Figura 4.4. Esquema general de la metodología para la caracterización del suelo.	60
Figura 4.5. Esquema general de la metodología utilizada para la caracterización del suelo mediante nube de puntos LiDAR.	61
Figura 4.6. Representación ejemplo de los modelos MDT, MDS y CHM.	62
Figura 4.7. Nube de puntos LiDAR clasificada: tierra (naranja) y no tierra (blanco).....	62
Figura 4.8. Modelos digitales del área de estudio: (a) MDT y (b) MDS.....	63
Figura 4.9. Perfil de elevación del MDT con resolución 2 metros del PNOA (rojo) y el MDT con resolución aproximada de 10 cm generada por el Zenmuse L1 (azul).....	64
Figura 4.10. CHM del área de estudio.....	64
Figura 4.11. Caracterización del suelo del área de estudio con altura umbral de 20 cm: vegetación (verde) y tierra (marrón).	65
Figura 4.12. Estudio de la clasificación de vegetación resaltando el arbusto mejor identificado: (a) nube de puntos LiDAR original, (b) caracterización del suelo por altura.....	65
Figura 4.13. Caracterización del suelo del área de estudio con altura umbral de 20 cm y radio mínimo de 25 cm: vegetación por altura (verde claro), por altura y radio (verde oscuro), tierra (marrón) y no clasificados (blanco).	66
Figura 4.14. Imagen del área de estudio dentro del Parque Nacional de Timanfaya, Google Maps®.	67
Figura 4.15. Perfil de elevación de nube de puntos con suelo clasificado y con vegetación clasificada de un arbusto aislado.	68

Figura 4.16. Perfil de elevación de nube de puntos con suelo clasificado y con vegetación clasificada de una agrupación de arbustos.	69
Figura 4.17. Firma espectral del suelo, vegetación y agua [56].	70
Figura 4.18. Esquema general de la metodología utilizada para la caracterización del suelo mediante imagen multiespectral.	71
Figura 4.19. Proceso de elección de valor umbral global mediante histograma bimodal.	72
Figura 4.20. Imagen MicaSense con valores NDVI en escala de verdes.	73
Figura 4.21. Histograma de los valores del índice NDVI.	74
Figura 4.22. Clasificación con umbral NDVI de 0,12 entre vegetación (blanco) y suelo (negro).	74
Figura 4.23. Comparación de la clasificación NDVI: (a) sin filtrado, (b) con filtrado de mediana 5x5.	75
Figura 4.24. Caracterización del suelo del área de estudio según NDVI (verde) sobre imagen MicaSense original.	75
Figura 4.25. Imagen MicaSense con valores MSAVI2 en escala de verdes.	76
Figura 4.26. Histograma de los valores MSAVI2.	76
Figura 4.27. Clasificación con umbral MSAVI2 de 0,22 entre vegetación (blanco) y suelo (negro).	77
Figura 4.28. Caracterización del suelo del área de estudio según MSAVI2 (naranja) sobre imagen MicaSense original.	77
Figura 4.29. Comparación de la caracterización del suelo: (a) imagen MicaSense original con las zonas de posible vegetación resaltadas en verde, (b) resultado con índice NDVI, (c) resultado con el índice MSAVI2, (d) resultado LiDAR según altura.	78

ÍNDICE DE TABLAS

Tabla 2.1. Información espectral y resolución espacial del Sentinel-2.	12
Tabla 2.2. Información espectral del sensor WorldView-2.	15
Tabla 2.3. Micasense RedEdge Dual: Información espectral y reparto de bandas entre sensores.	17
Tabla 3.1. Métricas de error de los mapas de batimetría con la imagen WV-2 de El Río.	39
Tabla 3.2. Comparación de las métricas de error de los mapas de batimetría con la imagen WV-2 y Pika L de El Río.	41
Tabla 3.3. Precisión de cada clase y global del mapa de hábitats bentónicos.	53
Tabla PC.1 Condiciones <i>hardware</i>	93
Tabla PC.2 Condiciones <i>software</i>	94
Tabla P.1 Factor de corrección según las horas trabajadas.	98
Tabla P.2 Coste total de los recursos <i>hardware</i>	99
Tabla P.3 Coste total de los recursos <i>software</i>	100
Tabla P.4 Coste total del Trabajo Fin de Máster.	103

ACRÓNIMOS

6S	<i>Second Simulation of a Satellite Signal in the Solar Spectrum</i>
AOD	<i>Aerosol Optical Depth</i>
BoA	<i>Bottom-of-Atmosphere</i>
CHM	<i>Canopy Height Model</i>
EITE	Escuela de Ingeniería de Telecomunicación y Electrónica
ESA	Agencia Espacial Europea
FOV	<i>Field of View</i>
GPIT	Grupo de Procesado de Imágenes y Teledetección
IGN	Instituto Geográfico Nacional
IHO	Organización Hidrográfica Internacional
IOCAG	Instituto de Oceanografía y Cambio Global
IMU	<i>Inertial Measurement Unit</i>
KNN	<i>K-Nearest Neighbours</i>
LiDAR	<i>Light Detection and Ranging</i>
MAE	Error Absoluto Medio
MDS	Modelo Digital de la Superficie
MDT	Modelo Digital del Terreno
ML	<i>Machine Learning</i>
MSAVI2	<i>Modified Soil Adjusted Vegetation Index</i>
MSI	Instrumento MultiEspectral
NIR	Infrarrojo cercano
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>

PNOA	Plan Nacional de Ortofotografía Aérea
PRIMO	Interfaz para el Procesado de Imágenes Multiplataforma
ROI	<i>Region of interest</i>
RSME	Raíz del Error Cuadrático Medio
SBM	<i>Sigmoid-Based Model</i>
S-KNN	<i>Subspace K-Nearest Neighbours</i>
SVM	<i>Support Vector Machine</i>
SWIR	Infrarrojo de onda corta
TFM	Trabajo Fin de Máster
TIN	<i>Triangulated Irregular Network</i>
ToA	<i>Top-of-Atmosphere</i>
ULPGC	Universidad de Las Palmas de Gran Canaria
WV-2	WorldView-2
ZEC	Zona Especial de Conservación

MEMORIA

Capítulo 1: INTRODUCCIÓN

1.1. ANTECEDENTES

La teledetección consiste en obtener información de un objeto o fenómeno mediante la absorción de radiación desde un sensor ubicado en una plataforma a cierta distancia del objetivo de estudio [1]. Se puede distinguir entre teledetección pasiva y activa. La teledetección pasiva se basa en aprovechar la energía solar reflejada en la superficie terrestre. En la mayoría de las aplicaciones en teledetección pasiva se utilizan sensores ópticos multiespectrales o hiperespectrales, normalmente a bordo de satélites o drones, que miden la energía en diferentes bandas espectrales. Por otro lado, la teledetección activa obtiene los datos a través de la medición de la energía reflejada que había sido emitida por una fuente artificial que, normalmente, se encuentra junto al receptor. Entre los sensores de teledetección activa destacan el radar y el LiDAR. Los sistemas radar hacen uso de ondas dentro del espectro electromagnético para obtener información del objetivo. Los sistemas LiDAR se basan en el mismo principio básico utilizado en la tecnología radar, aunque empleando específicamente dispositivos láser.

1.1.1. MONITORIZACIÓN MARINA

En la actualidad, la teledetección en las zonas costeras puede proporcionar información valiosa para caracterizar y vigilar ópticamente las aguas poco profundas. La Organización Hidrográfica Internacional (IHO) indica que la mitad de las aguas costeras poco profundas del mundo siguen sin cartografiarse o la información catalogada no es certera [2]. Además, alrededor del 15% (20 millones de km²) de la superficie terrestre del planeta se encuentra bajo algún tipo de protección.

Concretamente, en España, las zonas protegidas cubren el 27,4% de su superficie total y las regiones marinas preservadas superan el 12%. Sin embargo, sólo el 25% de las zonas litorales son objeto de un seguimiento detallado [3]. Se destaca que estas zonas costeras son esenciales para la conservación de la biodiversidad y la prestación de servicios básicos para la sociedad.

Una de las técnicas que permite monitorizar las zonas costeras es la batimetría [4]. La batimetría se puede definir como la determinación de la profundidad del fondo marino con relación al nivel del mar. Es decir, la batimetría puede ser definida como la topografía del fondo marino.

En la actualidad, para obtener los mapas de batimetría destaca el uso de imágenes de teledetección satelitales, por su resolución espacial y cobertura de grandes extensiones marinas. Para generar la batimetría con imágenes satelitales son de especial mención los modelos propuestos por Lyzenga [5] y Stumpf [6], así como modelos que se apoyan en técnicas *Machine Learning*, como *Support Vector Machine (SVM)* [7] o *K-Nearest Neighbor (KNN)* [8]. Además, se han analizado e implementado mejoras del modelo propuesto por Stumpf para generar mapas de batimetría haciendo uso de la regresión sigmoide (*Sigmoid-Based Model, SBM*) [9], modelo desarrollado por el Grupo de Procesado de Imágenes y Teledetección (GPIT) de la Universidad de Las Palmas de Gran Canaria. Un ejemplo de mapa de batimetría obtenida mediante el modelo sigmoide se presenta en la Figura 1.1.

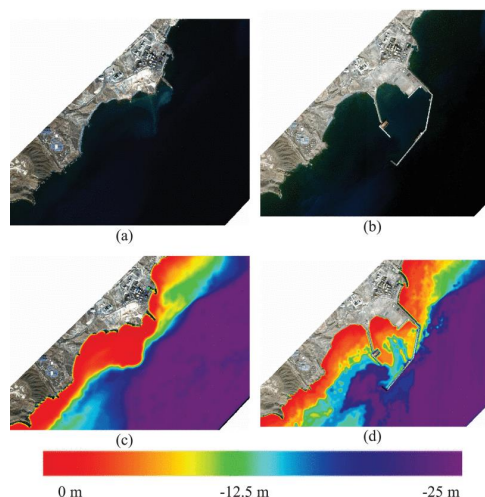


Figura 1.1. Batimetría durante y después de la construcción del puerto en la costa de Granadilla, Tenerife [9].

Además de la batimetría, para la monitorización marina es importante disponer de mapas de hábitas bentónicos, que consisten en la clasificación del tipo de fondo marino. Para determinar el tipo de fondo marino, en la actualidad se hace uso de imágenes de teledetección multiespectrales e hiperespectrales provenientes satélites y drones. Algunos de los sistemas de clasificación más utilizados para la generación de mapas de fondos marinos son el *Support Vector Machine (SVM)* [10],[11] o *Random Forest* [11]. Análogamente a la batimetría, en la Figura 1.2 se muestra un

ejemplo de mapa de hábitats bentónicos generado mediante SVM correspondiente a L'Olla, en la Isla de Cabrera.

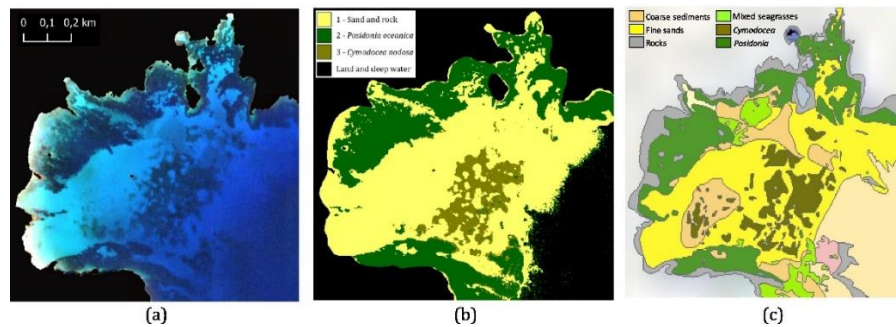


Figura 1.2. Mapa de hábitats bénticos de L'Olla, en la Isla de Cabrera [12].

Resaltar que, en el archipiélago canario han sido declaradas diversas reservas marinas por la importancia de las zonas costeras de las islas y la protección frente a la explotación de los recursos naturales. Una de ellas abarca el norte de la isla de Lanzarote, La Graciosa y los islotes del Archipiélago Chinijo [13]. Dentro de esta reserva marina se encuentran las aguas entre el norte de Lanzarote y el sur de la Graciosa, conocidas como El Río, que se muestra en la Figura 1.3. En esta área, destaca la presencia de la especie vegetal *Cymodocea nodosa*, un alga de gran relevancia en las aguas canarias y que presenta una elevada vulnerabilidad. Por ello, se incrementa la relevancia de monitorizar las aguas costeras de El Río.



Figura 1.3. El Río, parte de la reserva marina entre las islas de Lanzarote y La Graciosa [14].

1.1.2. MONITORIZACIÓN TERRESTRE

En el contexto de este TFM, además de la monitorización de las zonas costeras, anteriormente reseñadas, la teledetección abarca otros ámbitos de aplicación. La teledetección activa, específicamente la tecnología LiDAR, se utiliza para el estudio de zonas forestales y caracterización

de la superficie de parques nacionales [15]. El principio de funcionamiento de la tecnología LiDAR consiste en medir el intervalo de tiempo transcurrido entre la emisión de un pulso láser y la recepción de su eco o retorno tras incidir sobre la superficie forestal a estudiar. Con esta información, los sistemas LiDAR permiten generar una nube de puntos, en tres dimensiones, con la capacidad de describir la superficie del terreno a monitorizar.

En este contexto, en el archipiélago canario existe un gran número de espacios naturales protegidos. En total, las islas cuentan con 146 espacios, que cubren aproximadamente el 40% de la superficie del Archipiélago [16]. Entre estos lugares protegidos de las Islas Canarias se encuentran cuatro parques nacionales, como el Parque Nacional de Timanfaya [17], que es objeto de estudio en este TFM. Con una extensión de 51,07 km² cuenta con un gran número de endemismos vegetales y animales que le aportan su riqueza biológica. Sin embargo, el Parque Nacional de Timanfaya se ha visto comprometido por la aparición de especies invasoras, como es el caso de la vinagrera o calcosa (*Rumex lunaria*) [18], que se ha convertido en un problema importante en los últimos años por su creciente expansión en el territorio del parque y su resistencia a ser erradicada. Por ello, la vinagrera, que se muestra en la Figura 1.4, se encuentra en aislamiento dentro del parque y es necesario su monitorización y control.



Figura 1.4. *Rumex lunaria* en el Parque Nacional de Timanfaya, Lanzarote [19].

Este Trabajo Fin de Máster se basa en aplicar tecnologías de teledetección multiplataforma para determinar la batimetría y mapas de hábitats bentónicos, con el uso de imágenes multiespectrales e hiperespectrales, en la zona costera entre las islas de Lanzarote y La Graciosa, así como el uso de datos LiDAR y multiespectral para caracterizar el suelo en el Parque Nacional de Timanfaya.

1.2. OBJETIVOS

El objetivo principal de este TFM consiste en estudiar el estado de los litorales y parques nacionales del archipiélago canario mediante el procesado de imágenes multiespectrales e hiperespectrales de El Río, para la obtención de mapas de batimetría y hábitats bentónicos, y el procesado de datos LiDAR e imagen multiespectral del Parque Nacional de Timanfaya para la caracterización del suelo. En este TFM se hará uso de imágenes multiespectrales provenientes de los satélites WorldView-2 y Sentinel-2, junto a las imágenes capturadas a bordo de un dron por el sensor hiperespectral Pika L, el sensor Multiespectral MicaSense Dual y el sensor LiDAR Zenmuse L1. Para generar los mapas se aplicarán técnicas de *Machine Learning*, modelos físicos e índices de vegetación.

Para cumplir este objetivo principal, se han concretado los siguientes objetivos específicos:

- O1. Estudiar las tecnologías multiplataforma: sensores multiespectrales a bordo de los satélites Sentinel-2 y WorldView-2, sensor hiperespectral Pika L, multiespectral MicaSense Dual y LiDAR a bordo de un dron.
- O2. Estudiar los conceptos y algoritmos para el preprocesado de imágenes multiplataforma.
- O3. Procesar imágenes multiespectrales e hiperespectrales para la estimación de los mapas batimétricos y de hábitats bentónicos.
- O4. Procesar datos LiDAR e imagen multiespectral para la estimación de los mapas de caracterización de suelos.
- O5. Analizar los resultados obtenidos.

1.3. PETICIONARIO

Actúa como peticionario del presente Trabajo Fin de Máster (TFM) la Escuela de Ingeniería de Telecomunicación y Electrónica (EITE) de la Universidad de Las Palmas de Gran Canaria (ULPGC) como requisito indispensable para la obtención del título del Máster Universitario en Ingeniería de Telecomunicación, tras haber superado con éxito las asignaturas especificadas en el plan de estudios.

1.4. ORGANIZACIÓN DE LA MEMORIA

El presente documento se divide en tres secciones: Memoria, Pliego de condiciones y Presupuesto. La Memoria se estructura en cinco capítulos junto a la bibliografía utilizada.

En el capítulo 1 se exponen los antecedentes y necesidades que motivan la realización de este TFM. Además, se enumeran los objetivos que se pretenden alcanzar, el peticionario y la estructura del documento.

El capítulo 2 documenta los sensores multispectrales, hiperespectral y LiDAR, así como las plataformas utilizadas en este TFM. Adicionalmente, se detallan las técnicas de preprocesado generales utilizadas en imágenes de teledetección.

El capítulo 3 detalla la metodología utilizada para la monitorización marina con mapas de batimetría y hábitats bentónicos. Para ello, se expone el área de estudio marino, los productos utilizados, las técnicas empleadas en la obtención de ambos mapas y el análisis de los resultados obtenidos. Además, se realiza el estudio temporal de la zona donde se realiza la clasificación del fondo marino.

En el capítulo 4 se describe la metodología seguida para la monitorización terrestre mediante la caracterización del suelo. Específicamente, se detalla el área de estudio terrestre, así como los productos disponibles, las técnicas empleadas y la evaluación de los resultados.

Finalmente, en el capítulo 5 se recogen las conclusiones de este TFM y se proponen futuras líneas de trabajo.

Capítulo 2: SENSORES. PREPROCESADO DE IMÁGENES MULTIPLATAFORMA

En este TFM, se hace uso de la información obtenida mediante sensores pasivos y activo para alcanzar el objetivo de la monitorización marina y terrestre. La información es de carácter multiespectral e hiperespectral, ya que se obtiene de los sensores satelitales multiespectrales de alta resolución Sentinel 2-A y WorldView-2 (WV-2), junto al sensor multiespectral MicaSense Dual y al sensor hiperespectral Pika-L de muy alta resolución, que se utilizarán a bordo de un dron. Además, se obtendrá la información recogida por un sensor LiDAR, también a bordo de un dron.

En este capítulo se realiza una descripción de los sensores y sus productos. También, se hace una comparación de las especificaciones de los sensores para diferenciar el impacto de cada plataforma en el desarrollo del TFM. Finalmente, se describe el preprocesado que se aplica generalmente en imágenes de teledetección satelitales y dron.

2.1. SENSORES

Los sensores de teledetección son los instrumentos que permiten la adquisición de información de un objeto o fenómeno sin estar en contacto físico, es decir, a distancia del objetivo. Los sensores de teledetección se pueden clasificar en sensores activos y pasivos.

En la captura de las imágenes de teledetección, los sensores pasivos son aquellos que dependen principalmente de la energía solar reflejada. De esta manera, quedan sujetos a la necesidad de que existan buenas condiciones meteorológicas y suficiente luz solar para poder

obtener imágenes útiles. La mayoría de los sensores pasivos captan diferentes bandas espectrales entre el espectro visible y el infrarrojo cercano, ya que estas bandas incluyen información útil para diferentes aplicaciones. Al contrario que los pasivos, se consideran sensores activos a los que utilizan su fuente de emisión propia para enviar una señal al objetivo y recoger la energía reflejada en el mismo. Gracias a esto, los sensores activos son relativamente inmunes a algunas condiciones meteorológicas y pueden funcionar a cualquier momento del día. Estos sensores han ganado relevancia en los últimos años con la aparición de la tecnología LiDAR.

Además, una de las formas de caracterizar la captura de imágenes de teledetección se basa en la plataforma en la que se ubique el sensor, donde destacan los satélites y drones, y sus características espectrales. Los sensores a bordo de satélites multiespectrales más utilizados en el campo de estudio permiten la captura de imágenes de alta resolución espacial, del orden del metro con una cobertura total de la superficie terrestre y un tamaño de la imagen de varios kilómetros. Por otra parte, los sensores a bordo de drones mejoran la resolución espacial a centímetros, pero el alcance y cobertura de las imágenes capturadas están limitados al tiempo y zona del vuelo del dron.

En ambas plataformas se pueden ubicar sensores multiespectrales e hiperespectrales. Los sensores hiperespectrales se diferencian de los sensores multiespectrales en el número de bandas espectrales disponibles y el ancho de banda de cada una de ellas. En los sensores multiespectrales se dispone de una decena de canales aproximadamente, mientras que los sensores hiperespectral cuenta con una resolución espectral de cientos de canales, otorgando una amplia diversidad espectral. La Figura 2.1 muestra las diferencias de información espectral proporcionadas en imágenes RGB, multiespectrales e hiperespectrales.

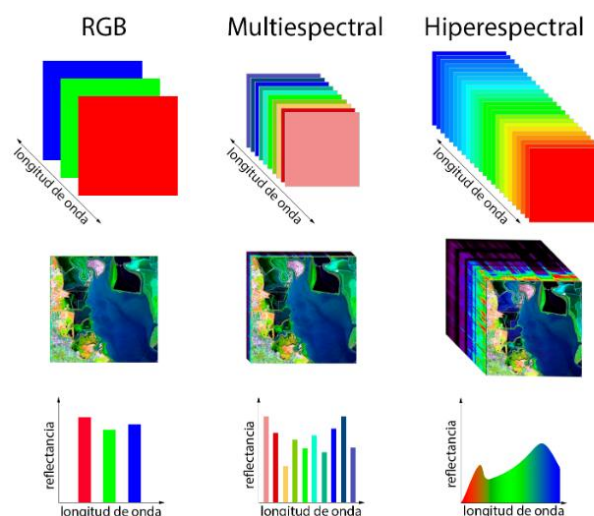


Figura 2.1. Comparativa espectral entre imágenes RGB, multiespectrales y hiperespectrales [20].

En este TFM, se utilizan productos multispectrales, hiperspectrales y LiDAR obtenidos por sensores ubicados en satélites y a bordo de un dron. A continuación, se detallan las características de los sensores satelitales, que incluyen la misión Sentinel-2 del programa Copernicus y el satélite WorldView-2. Posteriormente, se describen los sensores a bordo de un dron utilizados, como son el sensor hiperspectral Pika L, el sensor multispectral Micasense Dual y el sensor LiDAR Zenmuse L1.

2.1.1. SENSORES SATELITALES

▪ PROGRAMA COPERNICUS: SATÉLITES SENTINEL 2 A-B

Copernicus es el programa de Observación de la Tierra de la Unión Europea, liderada por la Agencia Espacial Europea (ESA) [21]. Este programa es de libre acceso tanto para la comunidad científica como la civil. Tiene como objetivo obtener información, mediante sus distintas misiones y distribuirla para la gestión y monitorización del medio ambiente y la seguridad civil. Entre los servicios que ofrece destacan la vigilancia marina, la vigilancia terrestre, el cambio climático, la seguridad y las emergencias. En la actualidad, el programa Copernicus dispone de 6 misiones [22] compuestas por satélites con diferentes características que permiten disponer de un amplio rango de información. Estas misiones cuentan con cargas de pago de distintas tecnologías, como radar o instrumentos de imágenes multispectrales para la monitorización terrestre, marina y atmosférica.

Para este TFM, se utilizan productos obtenidos de la misión Sentinel-2 del programa Copernicus. La misión Sentinel-2 [23] consiste en dos satélites idénticos, Sentinel 2-A y Sentinel 2-B, con la estructura que se muestra en la Figura 2.2. Los satélites Sentinel 2-A y 2-B fueron lanzados el 23 de junio de 2015 y el 7 de marzo de 2017, respectivamente. Ambos satélites operan de manera simultánea, desfasados 180° el uno del otro, a una altitud media de 786 km. Tienen una inclinación de 98.62° , un periodo de la órbita de 100.6 minutos y un tiempo de revisita de 10 días, reducido a 5 días entre ambos satélites por el desfase de 180° .




Figura 2.2. Representación visual de los satélites de la misión Sentinel 2.

Los satélites Sentinel-2 tienen como carga de pago el instrumento MultiEspectral (MSI), un sensor óptico que permite obtener una imagen en 13 bandas con una resolución de 12 bits, en el espectro visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR). La distribución de las bandas se muestra en la Figura 2.3. Además, se muestra la resolución espacial de cada banda, que puede ser de 10, 20 o 60 metros.




Figura 2.3. Clasificación espectral y por resolución espacial de las bandas del MSI [23].

La información espectral de los sensores de la misión Sentinel-2, así como su resolución espacial, se muestra de manera resumida en la Tabla 2.1.

Tabla 2.1. Información espectral y resolución espacial del Sentinel-2.

Banda Espectral	Longitud de onda central (nm)	Ancho de banda (nm)	Resolución Espacial (m)
1. Aerosol	443	20	60
2. Azul	490	65	10
3. Verde	560	35	10
4. Rojo	665	30	10
5. Rojo borde 1	705	15	20
6. Rojo borde 2	740	15	20
7. Rojo borde 3	783	20	20
8. NIR 1	842	115	10
8a. NIR 2	865	20	20
9. Vapor de agua	945	20	60
10. Cirros	1380	30	60
11. SWIR 1	1610	90	20
12. SWIR 2	2190	180	20

Los productos que ofrece Sentinel-2 son de cinco tipos, dependiendo del nivel de procesamiento, donde cada nivel modifica el anterior:

- Nivel 0: datos brutos con compresión.
- Nivel 1A: datos brutos sin compresión.
- Nivel 1B: imágenes preprocesadas con corrección radiométrica.
- Nivel 1C: imágenes preprocesadas y georreferenciadas, con el modelo WGS84 y proyección UTM.
- Nivel 2A: Imágenes 1C con preprocesado de correcciones atmosféricas.

Los productos de la misión Sentinel-2 con niveles 1C y 2A se pueden visualizar y descargar gratuitamente en el buscador Copernicus [24]. Además, el buscador permite obtener productos de otras misiones del programa Copernicus, como las medidas de ozono o dióxido de azufre proporcionados por la misión Sentinel-5P.

Los preprocesados expuestos en estos niveles se explican en la segunda parte de este capítulo.

▪ SATÉLITES DE TELEDETECCIÓN ESPACIAL WORLDVIEW-2

WorldView-2 (WV-2) es un satélite comercial de imágenes de alta resolución que lleva operando desde enero de 2010 [25]. Forma parte del sistema satelital WorldView, propiedad de Maxar [26]. En la Figura 2.4 se muestra una representación visual del WV-2. Orbita a una altura aproximada de 770 km, con un periodo orbital de 100 minutos y un tiempo de revisita de 1,1 días. Este satélite dispone de sensores que proveen imágenes pancromáticas y multiespectrales, con una resolución de 0,46 m y 1,84 m, respectivamente. Además de las cuatro bandas multiespectrales típicas (azul, verde, rojo y NIR), WV-2 dispone de cuatro bandas adicionales para un análisis multiespectral avanzado. La información multiespectral de 8 bandas permite mejorar la segmentación y clasificación de propiedades terrestres y marinas. Estas características lo convierten en uno de los satélites con mayor resolución disponible en el mercado.



Figura 2.4. Representación visual del satélite WorldView-2.

El WV-2 tiene como carga de pago un instrumento capaz de generar imágenes pancromáticas de 0,46 m de resolución en una banda de paso de 450-800 nm, junto a ocho bandas espectrales estrechas con una resolución de 1,84 m.

En la Figura 2.5 se muestra la respuesta espectral de la banda pancromática y las ocho bandas multispectrales del satélite WV-2. Además, la Tabla 2.2 presenta la información espectral de cada banda del sensor WV-2. Cada una de estas bandas multispectrales cuentan con sus propias características, que permiten aumentar el rango de aplicaciones [27].

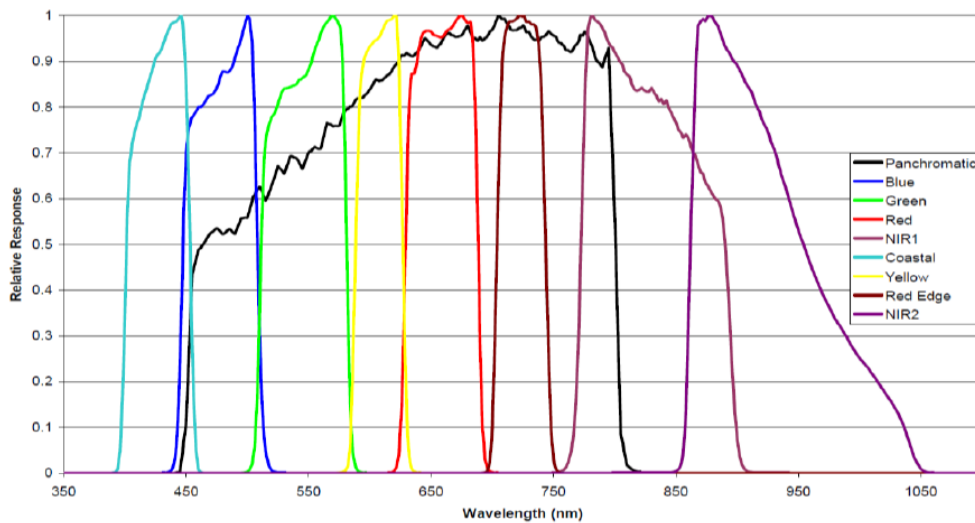


Figura 2.5 Respuesta espectral de las bandas del WorldView-2 [28].

Tabla 2.2. Información espectral del sensor WorldView-2.

Banda Espectral	Longitud de onda central (nm)	Banda de paso (nm)
1. Azul costero	427	400 – 450
2. Azul	478	450 – 510
3. Verde	546	510 – 580
4. Amarillo	608	585 – 625
5. Rojo	659	630 – 690
6. Rojo borde	724	705 – 745
7. NIR 1	831	770 – 895
8. NIR 2	908	860 – 1040

2.1.2. SENSORES DRON

- **SENSOR HIPERESPECTRAL PIKA L**

El sensor Pika L es una cámara hiperespectral compacta y ligera desarrollada por Resonon [29]. Este sensor, que se muestra en la Figura 2.6, se utilizará a bordo de un dron. Las dimensiones físicas del Pika L son de 115 x 104 x 66 mm y tiene un peso de 0,64 kg. Además, la cámara es tipo CMOS y posee una tasa de captura máxima de 249 fps. Dispone de varias opciones para regular el campo de visión (FOV) del objetivo. El FOV puede ser de 4°, 6°, 13°, 18°, 25°, 37° o 47°. En cuanto al consumo, requiere una potencia de 3,4 W mediante USB.



Figura 2.6 Sensor hiperespectral Pika L.

El sensor Pika L cubre el rango del espectro visible e infrarrojo cercano desde 400 a 1000 nm, repartido en 281 canales. La respuesta espectral se muestra en la Figura 2.7, en la que se puede apreciar un máximo alrededor de los 550 nm, longitud de onda que corresponde al verde, que permite capturar más información de esta banda al ser más sensible.




Figura 2.7. Respuesta espectral Pika L [29].

▪ SENSOR MULTIESPECTRAL MICASENSE REEDGE DUAL

MicaSense RedEdge Dual [30] está formado por la combinación de dos sensores multiespectrales de muy alta resolución de 5 bandas cada uno. Esta combinación permite su uso en aplicaciones como la identificación de malezas y especies vegetales o la investigación y conservación de ecosistemas. La Figura 2.8 muestra un ejemplo de instalación de los sensores a bordo de un dron.



Figura 2.8. Representación del sensor Micasense Dual a bordo de un dron.

Al combinar ambos sensores, se consigue información en 10 bandas espectrales diferentes. La Figura 2.9 muestra la distribución de las bandas en el espectro visible y el NIR. Además, se realiza la comparación con otros sensores multiespectrales a bordo de los satélites Sentinel 2-A y Landsat 8, ya que este sensor tiene como objetivo competir en el mercado de imágenes multiespectrales ofreciendo datos de mayor resolución espacial que los sensores a bordo de satélites. Las dimensiones físicas del sensor MicaSense RedEdge Dual son de 132 x 88 x 96 mm y tiene un peso de 0,745 kg, considerando los sensores y el kit de instalación en el dron. Tiene una resolución de 7,7 cm por píxel a una altura de vuelo de 120 m.




Figura 2.9. Distribución de las bandas espectrales del Micasense RedEdge Dual y comparación con otros sensores satelitales [30].

En la Tabla 2.3 se pueden observar las diferentes bandas espectrales del Micasense RedEdge Dual, así como la longitud de onda central de cada banda y su respectivo ancho de banda. Además, se indica la distribución de las bandas entre los dos sensores.

Tabla 2.3. Micasense RedEdge Dual: Información espectral y reparto de bandas entre sensores.

Banda Espectral	Longitud de onda central (nm)	Ancho de banda (nm)	Sensor
1. Azul costa	444	28	RedEdge <i>blue</i>
2. Azul	475	32	RedEdge
3. Verde 1	531	14	RedEdge <i>blue</i>
4. Verde 2	560	27	RedEdge
5. Rojo 1	650	16	RedEdge <i>blue</i>
6. Rojo 2	668	14	RedEdge
7. Rojo borde 1	705	10	RedEdge <i>blue</i>
8. Rojo borde 1	717	12	RedEdge
9. NIR 1	740	18	RedEdge <i>blue</i>
10. NIR 2	842	57	RedEdge

▪ **SENSOR LIDAR ZENMUSE L1**

Zenmuse L1 es un producto desarrollado por DJI Enterprise [31]. Este sistema incluye un módulo LiDAR combinado con una IMU (*Inertial Measurement Unit*) de alta precisión y una cámara con sensor CMOS, por lo que es capaz de combinar la nube de puntos LiDAR con una imagen RGB. La Figura 2.10 muestra el sensor Zenmuse L1.



Figura 2.10. Sensor LiDAR Zenmuse L1.

El funcionamiento de un sensor LiDAR se basa en estimar el tiempo transcurrido desde la emisión de un pulso óptico hasta la recepción del eco o retorno producido cuando la señal incide sobre un objeto situado sobre la superficie terrestre. Este proceso ocurre miles de veces por segundo y, cada vez que la luz incide en un objeto o superficie, esta se refleja y vuelve al dispositivo emisor registrando la energía percibida en las coordenadas específicas de cada punto. La información que se obtiene con un sensor LiDAR corresponde a puntos con información de distancia que dibujan la superficie. Además, si se considera la posición geográfica del sensor LiDAR y la posición relativa de la medida, se generan nubes tridimensionales de puntos que permiten describir detalladamente la superficie escaneada por el sensor y mapear modelos superficiales y de elevación digital con gran precisión.

En concreto, el sensor Zenmuse L1 es capaz de generar datos con una frecuencia de puntos efectiva de 240.000 puntos por segundo y con unas resoluciones vertical y horizontal máximas de 5 y 10 cm respectivamente a 50 metros de altura. Además, con la ayuda de la cámara RGB, se puede añadir coloración de diferentes modos a las nubes de puntos en tiempo real, ya sea por color real, coloración por elevación o coloración por reflectividad. Cabe destacar que el sensor utilizado posee unas dimensiones físicas de 152 x 110 x 169 mm con un peso aproximado de 930 gramos.

2.2. PREPROCESADO DE IMÁGENES MULTIPLATAFORMA

El preprocesado es el conjunto de técnicas y algoritmos necesarios que se realizan antes de generar el procesado de un producto para asegurar su validez y mejorar su calidad y precisión. En el caso de la teledetección, se eliminan las distorsiones en la captura de imágenes para que el resultado corresponda a los valores de reflectancia de la superficie terrestre o marina.

A continuación, se explican las técnicas de preprocesado básicas para imágenes de teledetección, como son la calibración radiométrica, para convertir los valores digitales capturados

en valores de reflectancia en la parte superior de la atmósfera (*Top-of-Atmosphere*, ToA), y la corrección atmosférica, que parte de los valores de reflectancia ToA y corrige el efecto de la atmósfera, obteniendo valores de reflectancia en la superficie terrestre o parte inferior de la atmósfera (*Bottom-of-Atmosphere*, BoA). Además, se describe el proceso de georreferenciación, que permite asegurar la coincidencia de coordenadas entre imágenes. La Figura 2.11 muestra un diagrama con el preprocesado aplicado. Existen, además, otros preprocesados exclusivos del entorno marino, como es la eliminación del reflejo solar.

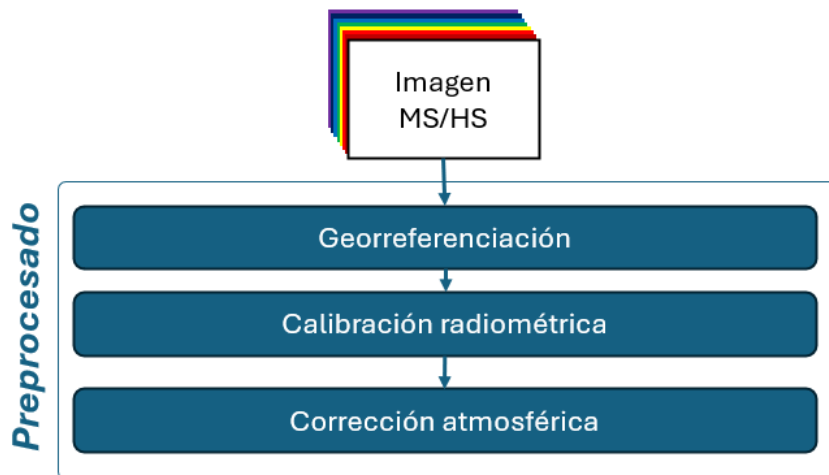


Figura 2.11. Diagrama del preprocesado para imágenes de teledetección.

2.2.1. GEORREFERENCIACIÓN

Las imágenes satélites y dron pueden no incluir información georreferenciada o, en su defecto, poseen errores en los valores de georreferencia de cada píxel. El proceso de georreferenciación consiste en corregir la localización de cada píxel utilizando puntos de control terrestres, que se pueden obtener mediante una imagen de referencia [32]. Para ello, es necesario identificar puntos idénticos en la imagen a corregir y una imagen de referencia. Estos puntos se definen como puntos de control y, con sus coordenadas, se realiza una transformación de los valores de posicionamiento de cada píxel de la imagen a corregir para adaptarlos a las coordenadas de referencia.

Este método de corrección de las coordenadas de cada píxel no es exacto, ya que, por ejemplo, existe un error en la selección de píxeles idénticos de las imágenes e incluso en la propia referencia. Sin embargo, utilizar esta técnica disminuye enormemente las diferencias en los sistemas de coordenadas. Esto permite mantener la coherencia geográfica en los mapas generados a partir de estas imágenes, como se describe en capítulos posteriores.

2.2.2. CALIBRACIÓN RADIOMÉTRICA

La corrección o calibración radiométrica es la técnica que consiste en modificar los niveles digitales de las imágenes procedentes de los sensores de observación de la Tierra, para poder corregir los problemas derivados su propio funcionamiento y las variaciones de iluminación [28]. Estos errores se pueden dar por deterioro o mal funcionamiento del sensor, pero también por la influencia de la atmósfera.

Esta técnica es un paso necesario para un correcto procesamiento de imágenes satelitales, ya que los niveles digitales o datos crudos de una imagen no son siempre uniformes, aunque la escena que capturen lo sea. Algunas de las razones de esta no uniformidad pueden ser la caída de las lentes o la variabilidad en la respuesta de los detectores, en la ganancia y en el *offset*. Estos fallos producen un efecto de rayas verticales y bandas en la imagen.

El funcionamiento de esta corrección se basa en la transformación de valores digitales de píxeles en unidades físicas de reflectancia para conseguir que la imagen muestre las propiedades de la superficie y la atmósfera sin la influencia de fallos en los sensores. Además, permite la eliminación del bandeo ocasionado por el desajuste de sensibilidad de los sensores.

La Figura 2.12 muestra el efecto de bandeo de una imagen cruda. La no uniformidad presente en la Figura 2.12a se refleja como líneas verticales claras y oscuras que se han exagerado para clarificar el ejemplo. La corrección radiométrica, como se muestra en la Figura 2.12b, suaviza este bandeo dejando una imagen más uniforme.




Figura 2.12. Datos crudos de una imagen WV-2 con bandeo exagerado [28].

2.3. CORRECCIÓN ATMOSFÉRICA

La corrección radiométrica trata de corregir problemas mecánicos en el sensor que generan valores erróneos en píxeles concretos, así como convertir los valores digitales en radiancia a la entrada del sensor. Por su parte, la corrección atmosférica trata de evaluar y eliminar las distorsiones que la atmósfera introduce en los valores de radiancia que llegan al sensor desde la superficie terrestre, para obtener los valores de reflectancia BoA a partir de la información espectral ToA.

Para realizar la corrección atmosférica es necesario utilizar algoritmos avanzados para lograr resultados adecuados en aplicaciones de teledetección costera. En este TFM se hace uso del modelo *Second Simulation of a Satellite Signal in the Solar Spectrum* (6S). Este modelo es el más preciso para el caso de estudio, según estudios anteriores [33].

6S es un modelo avanzado que permite simular la reflexión de la radiación solar con una atmósfera libre de nubes [34]. El código de transferencia radiativa 6S estima la reflectividad aparente ToA teniendo en cuenta los efectos de absorción de los gases, la difusión de las moléculas y aerosoles presentes en la atmósfera, y la falta de homogeneidad de la reflectividad de la superficie terrestre.

6S define la reflectividad ToA como ρ , expresada en la siguiente ecuación:

$$\rho(\theta_s, \theta_v, \Delta\phi) = tg(\theta_s, \theta_v) \left\{ \rho_a(\theta_s, \theta_v, \Delta\phi) + \left[e^{-\tau/\mu_s} + td(\theta_s) \right] \frac{\rho_c e^{-\tau/\mu_v} + \rho_e td(\theta_v)}{1 - \rho_e S} \right\}, \quad (2.1)$$

donde $\mu_s = \cos(\theta_s)$, $\mu_v = \cos(\theta_v)$, $\Delta\phi$ corresponde a la diferencia entre el azimut solar y satelital, tg es la transmisibilidad de los gases, ρ_a representa la reflectividad atmosférica, ρ_c es la reflectividad del objetivo, ρ_e representa el entorno de reflectividad alrededor de ρ_c , τ corresponde al espesor atmosférico (*Aerosol Optical Depth*, AOD), S es el albedo esférico de la atmósfera y $td(\theta_s)$, $td(\theta_v)$ representan la transmitancia difusa de la atmósfera.

Para utilizar la ecuación (2.1), es necesario proporcionar ciertos parámetros que se basan en la localización geográfica de la región reflejada en la imagen a preprocesar. Estos parámetros corresponden a las condiciones atmosféricas, modelo de aerosol, concentración de aerosoles, altitud del objetivo y la reflectancia del entorno.

2.4. RESUMEN

En este capítulo se han presentado las plataformas y los sensores utilizados en este TFM, comprendidos por los sensores multiespectrales de los satélites Sentinel-2 y WorldView-2, junto al sensor multiespectral Micasense Dual, el sensor hiperespectral Pika L y el sensor LiDAR Zenmuse L1. De estos sensores, se han descrito sus funcionalidades y características principales, en las que destacan las resoluciones espacial y espectral. Las resoluciones espaciales más elevadas se encuentran en los sensores a bordo de un dron, mientras que la mayor diversidad espectral se presenta en el sensor hiperespectral dron. Además, cabe destacar el impacto económico de cada uno de los sensores descritos, donde los productos obtenidos mediante sensores dron presentan un gasto más elevado que los sensores satelitales.

Posteriormente, se han enumerado las técnicas de preprocesado básicas utilizadas para corregir las imágenes satelitales y dron, que consisten en la georreferenciación, calibración radiométrica y las correcciones atmosféricas. A continuación, se ha realizado una breve explicación de cada técnica, así como la necesidad de su aplicación y los errores que corrigen en la imagen.

En el próximo capítulo se presenta el estudio de la generación de mapas de batimetría y hábitats bentónicos, con el fin de estudiar el fondo marino de uno de los ecosistemas bajo estudio: El Río. A lo largo del capítulo, se explican los modelos empleados en la obtención de ambos mapas junto a un análisis de los resultados en las distintas plataformas.

Capítulo 3: MONITORIZACIÓN MARINA: BATIMETRÍA Y HÁBITATS BENTÓNICOS EN EL ECOSISTEMA DE EL RÍO

En este TFM, se estudian zonas costeras mediante mapas de batimetría y hábitats bentónicos utilizando algoritmos *Machine Learning* en imágenes multiespectrales e hiperespectral.

El área de estudio escogida para la monitorización marina se encuentra en la zona conocida como El Río, entre Caleta del Sebo, al sur de la isla de La Graciosa, y las salinas del Río, al norte de la isla de Lanzarote. La zona de estudio se muestra en la Figura 3.1. Cabe señalar que su nombre hace referencia al estrecho canal de mar que separa ambas islas, donde el flujo de las mareas se asemeja a una corriente de agua continua.



Figura 3.1. El Río desde Lanzarote con La Graciosa de fondo [35].

El Río posee una diversidad de comunidades bentónicas de gran interés natural, declarándose, en septiembre de 2011, como Zona Especial de Conservación (ZEC) de los Sebadales de La Graciosa [14]. El objetivo de la declaración del ZEC es asegurar la conservación de la biodiversidad de la zona frente al impacto de las actividades humanas. Además, el área que comprende El Río está incluido en la Reserva Marina del entorno de la isla de La Graciosa e islotes del norte de Lanzarote [35], establecido por el Ministerio de Agricultura, Pesca y Alimentación en 1995, con el propósito de proteger especies de interés pesquero, así como de flora marina *Cymodocea nodosa*, llamada localmente sebadal.

Para llevar a cabo la monitorización marina de El Río, se hace uso de diversos productos multispectrales e hiperespectral capturados en la zona, que se exponen a continuación:

1. **Imagen multispectral WV-2 del 22 de enero de 2022**, como la fuente de datos principal para generar los mapas de batimetría y hábitats bentónicos de la zona.
2. **Imagen hiperespectral Pika L del 30 de octubre de 2021**, utilizada con el fin de generar mapas de batimetría y hábitats bentónicos de muy alta resolución en un área más limitada.
3. **Imágenes multispectrales Sentinel-2 con nivel de procesamiento 2A**, utilizadas para realizar un estudio de la evolución del litoral y fondo marino en el área de estudio durante los últimos años, aprovechando el libre acceso a los mismos.

Las imágenes presentadas se muestran en la Figura 3.2, que presenta, a su vez, la extensión de cada uno respecto al área de estudio.



Figura 3.2. Productos de El Río para la monitorización marina: imagen WV-2 del 22/01/2022 (gris), imagen Pika L del 30/10/2021 (amarillo) e imagen Sentinel-2 del 28/11/2022 (azul).

En este capítulo se describen las técnicas de preprocesado para aplicaciones marinas y se presentan los resultados obtenidos. Posteriormente, se explican las metodologías utilizadas para obtener los mapas de batimetría de las imágenes disponibles de El Río. Además, se muestran y analizan los resultados generados. Finalmente, se describen las metodologías y resultados de los mapas de hábitats bentónicos, añadiendo un estudio del fondo marino de la zona de estudio en los últimos años.

En la Figura 3.3 se presenta el esquema general de la metodología utilizada para la obtención de mapas de batimetría y hábitats bentónicos. Inicialmente, se parte de las imágenes WV-2 y Pika L y se aplica el preprocesado para aplicaciones marinas. Con las imágenes preprocesadas, se obtienen los mapas de batimetría y hábitats bentónicos. Para la batimetría, se utiliza un modelo empírico y otro basado en *Machine Learning*. Ambos modelos son entrenados con una batimetría de referencia. Por otro lado, para la clasificación de fondos, se hace uso de las imágenes Sentinel 2 para el estudio temporal de El Río, utilizado para coordinar una campaña de campo que capture los datos de entrenamiento. Con esta información, se entrena un modelo *Machine Learning* para generar el mapa de hábitats bentónicos. Finalmente, se realiza un análisis de los resultados.

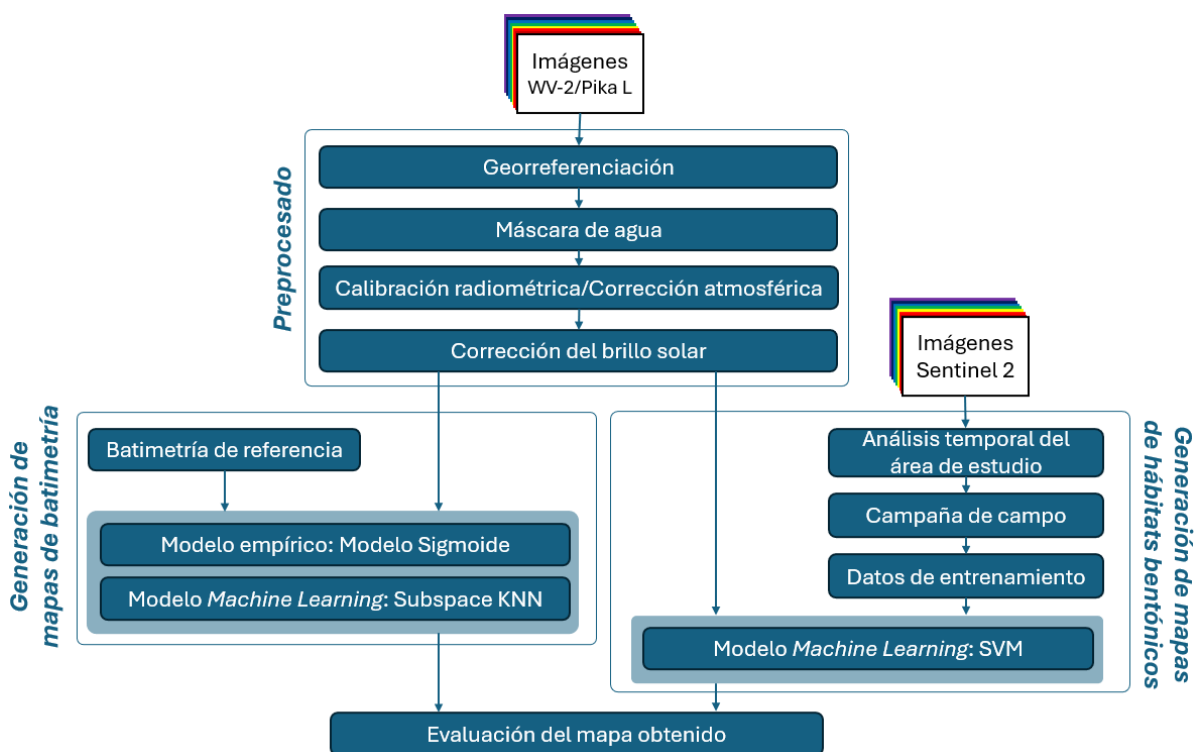


Figura 3.3. Esquema general de la metodología para la obtención de mapas de batimetría y hábitats bentónicos.

Para llevar a cabo esta metodología, se hace uso de varias herramientas *software*. Para realizar la georreferenciación y como visualizador de imágenes, se utiliza la aplicación *ArcMap* [36], dentro de la herramienta *ArcGIS Desktop* desarrollado por *Esri*, en su versión 10.8.2. Por otro lado,

el GPIT ha desarrollado el *software* Interfaz para el Procesado de Imágenes Multiplataforma (PRIMO). PRIMO permite realizar el resto del preprocesados y la generación de mapas de batimetría. Por último, la herramienta ENVI [37], desarrollada por NV5 Geospatial Solutions, se utiliza para la generación de mapas de hábitats bentónicos.

3.1. PREPROCESADO PARA APLICACIONES MARINAS

En el capítulo anterior, se describieron las técnicas de preprocesado básicas en imágenes de teledetección. Sin embargo, dependiendo de la aplicación a la que se destinen las imágenes, se requiere de preprocesados adicionales para conseguir una imagen sin ruido.

En este apartado, se explican las dos técnicas de preprocesado específicas para aplicaciones marinas utilizadas en las imágenes de El Río. En primer lugar, se describe la máscara de agua, que permite identificar las superficies marinas y separarlas de las terrestres. En segundo lugar, se encuentra la corrección del brillo solar, que pretende eliminar los destellos ocasionados por el reflejo solar debido al oleaje. Finalmente, se presentan los resultados obtenidos de aplicar todas las técnicas de preprocesado.

3.1.1. MÁSCARA DE AGUA

La máscara de agua es la técnica que permite identificar las masas de agua respecto a las superficies terrestres. Con su aplicación, se realzan las masas de agua al eliminar el suelo y vegetación terrestres, lo que elimina información no relevante de la imagen, facilitando las tareas posteriores de preprocesado y procesado.

El proceso para el enmascaramiento del agua en este TFM consiste en el uso del Índice de Agua de Diferencia Normalizada (*Normalized Difference Water Index*, NDWI) [38]. El NDWI compara la diferencia entre la banda del verde y la NIR, siguiendo la ecuación (3.1). Las longitudes de onda de la banda verde maximizan la reflectancia de la superficie del agua, mientras que las longitudes de onda de NIR tienen baja reflectancia de las masas de agua. Sin embargo, la banda NIR tiene alta reflectancia de la vegetación terrestre y zonas de suelo.

$$NDWI = \frac{Verde - NIR}{Verde + NIR} \quad (3.1)$$

3.2. CORRECCIÓN DEL BRILLO SOLAR

El brillo solar en la superficie del agua es una fuente importante de ruido en imágenes satelitales y dron. El brillo solar se produce cuando la superficie del agua, debido al oleaje, orienta la reflexión especular de la luz solar hacia el sensor. Por ello, esta fuente de ruido está sujeta al estado de la superficie marina, el nivel de oleaje, la posición del Sol y la posición del sensor en el momento de la captura. Debido a la baja reflectividad del agua marina, la aportación del brillo solar puede ser superior a la reflectividad del agua en determinadas ocasiones.

Hay diferentes métodos de corrección del brillo solar basados en la elevada absorción de la banda NIR en el agua, lo que permite atribuir, tras las correcciones atmosféricas, la reflectividad en esas longitudes de onda al brillo solar reflejado. Entre ellos, se encuentra el método de Hedley et al. [39].

La corrección de Hedley se basa en obtener una función lineal del brillo solar para cada banda espectral, asumiendo que las condiciones atmosféricas son iguales en toda la imagen y que no existe turbidez o no uniformidad en la superficie marina. Para ello, se hace uso de regiones de la imagen correspondientes a zonas de gran profundidad que tengan oleaje continuo. Estas regiones tienen un nivel mínimo de reflectividad en la banda NIR, que se ve alterado por el brillo solar provocado por el oleaje.

La Figura 3.4 muestra una representación gráfica del método de Hedley, con la curva de regresión obtenida en una cierta región de ejemplo. La gráfica presenta la información de la reflectividad en una banda visible, como eje de ordenadas, y la reflectividad en la banda NIR, como eje de abscisas. Los puntos azules o píxeles de entrenamiento, correspondientes a la región seleccionada, están dispuestos con cierta linealidad, de la que se obtiene la pendiente mediante una regresión lineal. De esta manera, los píxeles de la banda visible se corregirán reduciendo su valor de reflectividad utilizando la pendiente obtenida y marcando como referencia de corrección el valor de reflectividad libre de brillo solar. Este valor de referencia corresponde con el píxel de entrenamiento que presente la mínima reflectividad en la banda NIR. El proceso de corrección explicado se repite para cada una de las bandas visibles disponibles en la imagen de estudio.

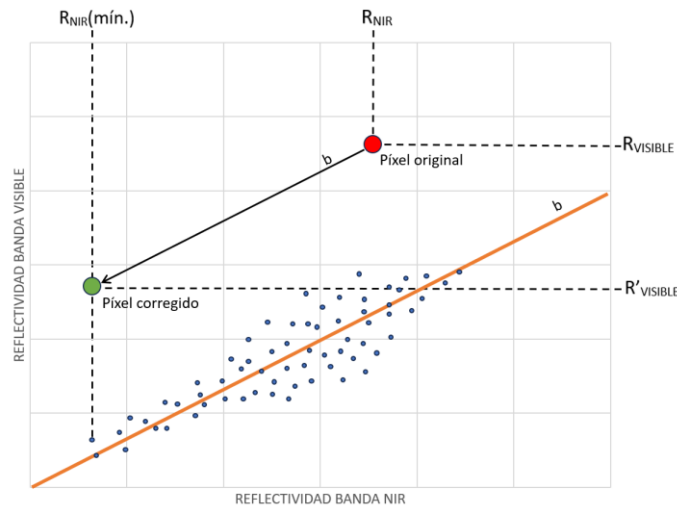


Figura 3.4. Representación gráfica de la corrección del brillo solar mediante el método de Hedley.

El método de Hedley es el más utilizado para la corrección del brillo solar en imágenes satelitales de alta resolución, debido al uso de regresiones lineales que ofrecen resultados eficientes respecto al cómputo necesario. Esto se refleja en la ecuación para la transformación de los valores de reflectividad que se obtiene utilizando la pendiente calculada con la regresión lineal. A partir la Figura 3.4, la ecuación de corrección del brillo, mediante el método de Hedley, para un píxel sería la siguiente,

$$R'_{VISIBLE} = R_{VISIBLE} - b[R_{NIR} - \min(R_{NIR})], \quad (3.2)$$

donde $R'_{VISIBLE}$ corresponde con la reflectividad corregida del píxel en la banda visible, $R_{VISIBLE}$ corresponde con la reflectividad original del píxel en la banda visible, b es la pendiente obtenida de la regresión lineal con los píxeles de entrenamiento, R_{NIR} corresponde con la reflectividad original en la banda NIR del píxel y $\min(R_{NIR})$ corresponde con el valor de reflectividad NIR mínimo de los píxeles de entrenamiento.

3.2.1. RESULTADOS

La Figura 3.5 muestra el proceso de georreferenciación realizado en la imagen WV-2. Para esta imagen, se ha tomado como referencia el puerto de Caleta de Sebo, La Graciosa, como punto de control, ya que es una estructura que no se ha visto modificada en el tiempo transcurrido entre la imagen de estudio y la referencia.



Figura 3.5. Georreferenciación en imagen WV-2 de El Río: (a) imagen de estudio y referencia superpuestas con los puntos de control resaltados como circunferencias amarillas, (b) imágenes superpuestas tras la georreferenciación.

La Figura 3.6 muestra la imagen WV-2 original de El Río, junto al resultado de la máscara de agua y de aplicar la calibración radiométrica y las correcciones atmosféricas. En este caso, tras aplicar el índice NDWI a la imagen se ha aplicado un umbral de 0,7 para diferenciar entre las superficies marina y terrestre. Se puede apreciar que la superficie marina destaca una vez aplicada la técnica. Por otra parte, se ha ajustado el modelo de corrección atmosférica 6S con las condiciones de verano a latitudes medias, perfil de aerosoles marítimo, AOD de 0.11, altitud del satélite de 770 km y un perfil de reflectancia de agua clara. El valor de AOD se ha obtenido desde la plataforma Giovanni de la NASA [40], que permite la visualización de parámetros geofísicos en cualquier región terrestre. En este caso, se escogió el valor de AOD ofrecido por la plataforma MODIS-Aqua el día 22 de enero de 2022.




Figura 3.6. Resultados del preprocesado en la imagen WV-2 de El Río: (a) imagen original del 22 de enero de 2022, (b) máscara de agua de la imagen anterior, y (c) calibración radiométrica y corrección atmosférica de la imagen anterior.

En este TFM, la imagen WV-2 de El Río no requiere de la corrección del brillo solar o su uso no mejoraría considerablemente la calidad de la imagen. Esto se debe al mínimo oleaje y condiciones atmosféricas óptimas que presenta la imagen, resaltando estas características como argumentos de su elección para este caso de estudio. Sin embargo, esta técnica de preprocesado también sirve de utilidad para la imagen hiperespectral obtenida por el sensor Pika L, que presenta brillo solar.

Además, se debe considerar que no es necesario aplicar correcciones atmosféricas en imágenes dron donde el vuelo se realice a baja altitud, como en este caso, ya que la altura del sensor durante el vuelo es entre 50 y 100 metros y el efecto de la atmósfera se desprecia o no afecta a la imagen capturada. Este criterio es válido tanto para aplicaciones marinas como terrestres, por lo que se ha realizado únicamente corrección de brillo solar a la imagen dron.

La Figura 3.7 muestra el resultado de aplicar la corrección del brillo solar a la imagen dron Pika L de El Río, donde se compara la imagen original Figura 3.7a con la imagen obtenida tras el preprocesado Figura 3.7 b.

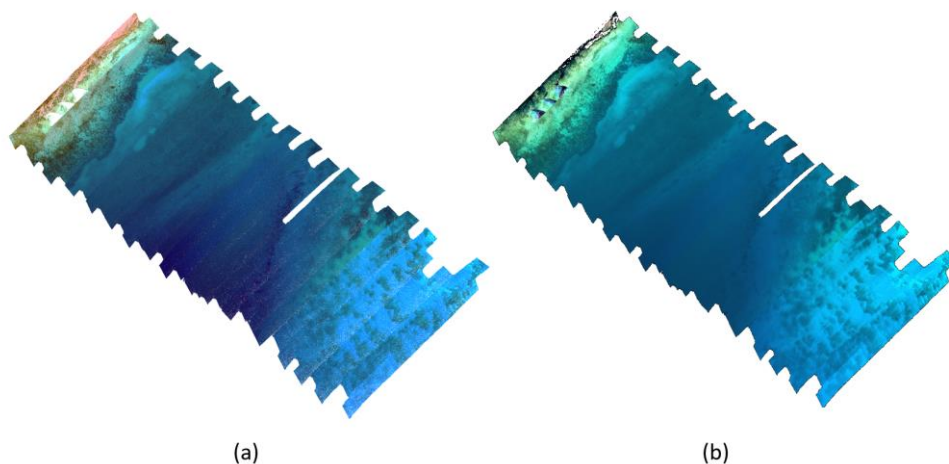


Figura 3.7. Resultado de la corrección del brillo solar: (a) imagen original Pika L del 30 de octubre de 2021 (b) imagen anterior tras aplicar el método de Hedley.

3.3. BATIMETRÍA

La batimetría se define como la estimación de la profundidad del fondo marino respecto al nivel del mar. Los mapas de batimetría son aquellos en los que a cada píxel de la imagen se le asigna un valor de profundidad, y suelen ser mostrados mediante una escala de colores para mejorar la visualización.

En la actualidad, los mapas de batimetría en zonas costeras se pueden generar mediante el uso de sensores multiespectrales e hiperespectrales a bordo de satélites, aviones o drones. Estos sensores capturan la luz solar que se refleja en el fondo marino, según la capacidad de penetración de cada banda espectral.

Las imágenes capturadas por estos sensores se procesan para obtener los mapas de batimetría. Las metodologías más comunes para generar estos mapas se basan en los modelos físicos semiempíricos, como el propuesto inicialmente por Lyzenga [5], y empíricos, como el método más empleado en la actualidad presentado por Stumpf et al. [6]. Los modelos físicos semiempíricos requieren disponer de múltiples variables para cada banda espectral, valores que, normalmente, resultan difíciles de obtener. Por otro lado, los modelos físicos empíricos únicamente requieren de una fase de entrenamiento utilizando un conjunto de datos de referencia. Por ello, los modelos empíricos tienen una mayor aceptación como método para la generación de mapas de batimetría, ya que no dependen de multitud de parámetros.

Además, en los últimos años, los métodos basados en *Machine Learning* han surgido como una útil alternativa para la generación de mapas de batimetría [7],[8]. Estas técnicas utilizan datos de entrenamiento para obtener modelos que realizan el mapeado entre los datos de entrada y los datos de salida deseados. Para ello, utilizan métodos de mayor coste computacional que permiten aprovechar mejor la información sin suposiciones físicas.

La Figura 3.8 presenta el esquema general de la metodología seguida en este TFM para la obtención de los mapas de batimetría, a partir de las imágenes satelital y dron. En primer lugar, se realiza el preprocesado de la imagen, según los pasos comentados en el capítulo anterior. En segundo lugar, la generación de mapas de batimetría se realiza mediante un modelo físico empírico basado en la función sigmoide y un modelo basado en *Machine Learning*. Ambos modelos precisan de datos de entrenamiento para procesar las imágenes. Estos datos corresponden a las isobatas de referencia de 1 metro de resolución de profundidad capturadas entre los años 2000 y 2001 obtenidas dentro del Plan de Ecocartografías del litoral español por el Ministerio para Transición Ecológica y el Reto Demográfico [41]. Finalmente, se realiza la evaluación de la calidad de los resultados mediante métricas de error entre los mapas generados y la referencia.

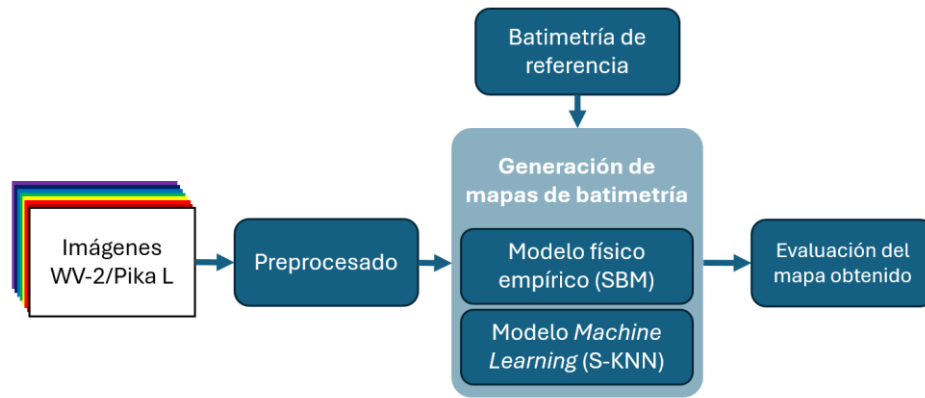


Figura 3.8. Esquema general de la metodología utilizada para la obtención de mapas de batimetría.

A continuación, se explican los modelos utilizados para obtener los mapas de batimetría en este TFM. Los modelos utilizados son el modelo físico empírico *Sigmoid-Based Model* (SBM) y el modelo de *Machine Learning* denominado *Subspace K-Nearest Neighbors* (S-KNN). Posteriormente, se realiza el análisis multiplataforma de los resultados, comparando los mapas obtenidos con la imagen satelital WV-2 y la imagen dron Pika L.

3.3.1. MODELO BASADO EN SIGMOIDE (SBM)

El modelo más implementado y de mayor relevancia para la obtención de mapas de batimetría mediante imágenes multiespectrales satelitales es el modelo empírico propuesto por Stumpf et al. [6]. El modelo de Stumpf presenta una relación lineal entre la profundidad y la relación del logaritmo neperiano de la reflectancia observada a dos longitudes de onda diferentes. Estas longitudes de onda, normalmente, corresponden al verde y al azul, ya que poseen mayor penetrabilidad en el medio, o menor dispersión en la columna de agua.

El modelo Stumpf, al realizar la regresión lineal, se centra en el tipo de fondo más común en la imagen, ya que, matemáticamente, se asume que no hay dependencia con el tipo de fondo. Sin embargo, en grandes áreas existen diferentes pendientes y parámetros para cada tipo de fondo, lo que provoca que el modelo pierda precisión en tipos de fondo menos comunes en la imagen. Además, la linealidad de Stumpf se ve comprometida en zonas de aguas profundas. En estas zonas, la atenuación de las bandas es muy alta y, a partir de cierta profundidad, su coeficiente de atenuación alcanza un valor máximo, es decir, se satura.

A partir de la saturación de la radiancia en píxeles profundos, investigadores del GPIT de la ULPGC implementaron una mejora en el modelo Stumpf basada en la capacidad de modelar la curva

de saturación de dicho modelo mediante una función sigmoide modificada. El modelo SBM [9] propone la siguiente ecuación para la obtención de la batimetría:

$$f = m_1 \left(\frac{1}{1 + e^{-m_0 z}} - \frac{1}{2} \right) + m_2, \quad (3.3)$$

donde m_0 corresponde a la escala de las entradas, m_1 corresponde a la escala de la sigmoide, m_2 es la componente continua, la constante $(-\frac{1}{2})$ permite centrar la sigmoide en cero, z es la profundidad y f corresponde a la relación de Stumpf. De esta manera, la profundidad se puede calcular como:

$$z = -\frac{1}{m_0} \ln \left(\frac{2}{2f - 2m_2 + m_1} - 1 \right) \quad (3.4)$$

Este modelo no presenta el comportamiento de Stumpf en zonas de aguas profundas al hacer uso de una sigmoide, ya que modela la saturación de manera intrínseca a la función de regresión sin necesidad de diezmar los datos. Para los píxeles de aguas profundas, se asigna el mismo valor reflectancia a partir del punto de saturación. Además, permite mantener la linealidad de Stumpf en valores cercanos a cero, es decir, con poca profundidad.

3.3.2. SUBSPACE K-NEAREST NEIGHBORS (S-KNN)

K-Nearest Neighbours [42] es un método ML supervisado que se basa en la clasificación de un nuevo dato a una clase según la distancia euclídea dentro de un espacio de características. La clasificación de una nueva entrada en el sistema es determinada por la clase más común entre los k vecinos más próximos, siendo k el parámetro que indica el número de puntos vecinos para tener en cuenta. Para ello, se parte de un espacio de características en el que a cada dato de entrenamiento se le asigna una clase. Al insertar un nuevo dato al sistema, se calcula la distancia euclídea con el resto de los puntos del espacio y se clasifica como la clase más común entre los k vecinos de menor distancia, siguiendo una votación por mayoría. Cabe destacar que, en este caso, se emplea la distancia euclidiana ya que es la más común y obtiene resultados óptimos. No obstante, se podrían utilizar otras distancias como la distancia de Manhattan.

La Figura 3.9 muestra un ejemplo de clasificación mediante KNN de un punto entre dos clases y con un k de cinco vecinos. En primer lugar, se puede observar el espacio de características, donde las clases se separan en puntos azules y naranjas y el nuevo dato se representa como un punto negro. Posteriormente, se obtiene la información de la clase de los cinco puntos más cercanos,

donde la clase azul tiene la mayor presencia. Por ello, al realizar la votación por mayoría, el nuevo dato se clasifica en la clase azul.




Figura 3.9. Ejemplo de clasificación KNN con $k = 5$: (a) espacio de características con dos clases, azul y naranja, y un dato de entrada, negro, (b) clasificación del dato de entrada como azul.

Subspace K-Nearest Neighbors es un modelo en el que se combina KNN con el método *Random Subspace*, una técnica de *Ensemble Learning* o Aprendizaje por Grupos. El concepto de *Ensemble Learning* [43] consiste en clasificar dividiendo los datos de entrenamiento en distintos subconjuntos y entrenando varios modelos ML del mismo tipo con las mismas características con cada subconjunto. La clasificación final se realiza agrupando las decisiones individuales de cada uno de los modelos y, posteriormente, aplicando una función de decisión, que normalmente es la votación por mayoría. Este concepto se asemeja al caso de un grupo de expertos que, ante un problema, aportan opiniones individuales y se llega a consenso para tomar una decisión final en grupo. De esta manera, la decisión obtenida grupalmente mejora respecto a cada una de las decisiones individuales.

Para la implementación de este modelo, se parte de un conjunto de datos de entrenamiento finito que se divide en tantos subconjuntos como modelos a entrenar. Los parámetros del *Ensemble Learning* son el número de subconjuntos y modelos a entrenar y el método para muestrear y dividir el conjunto de datos. La división del conjunto de datos se puede realizar de diferentes maneras. En este caso, se utiliza el método *Random Subspace*, que consiste en segmentar el conjunto de datos de manera aleatoria y sin que existan datos repetidos en diferentes subconjuntos. La Figura 3.10 muestra un esquema general de la fase de entrenamiento de un modelo S-KNN.

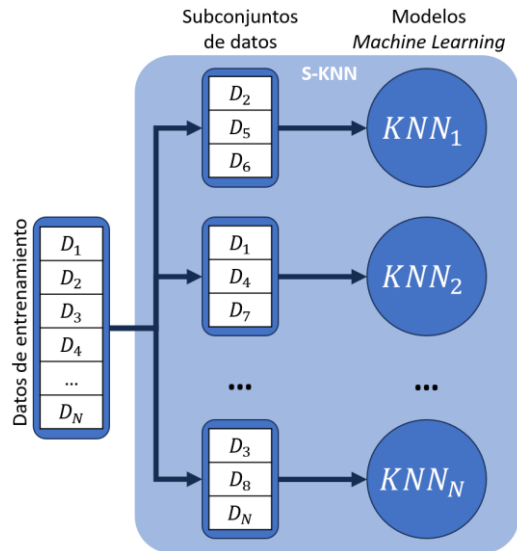


Figura 3.10. Esquema general de la fase de entrenamiento de un sistema S-KNN.

Posteriormente, ante una nueva entrada, se obtiene un resultado por cada modelo entrenado, y a la salida se aplica un promediado, en el caso de utilizar regresión, o una votación, en el caso de la clasificación, para determinar la salida conjunta del grupo de modelos.

Tras terminar el entrenamiento de los modelos, inicia el proceso de clasificación. La Figura 3.11 muestra el esquema general de clasificación del S-KNN. Ante un dato de entrada, este se reparte a cada uno de los modelos KNN, que generan su propia predicción o salida. Estas predicciones pasan por un proceso de decisión para generar la salida del sistema, es decir, la clasificación del dato de entrada. En S-KNN, la decisión de la salida grupal se realiza mediante mayoría o moda, es decir, se elige la clase más común entre las predicciones de cada modelo.

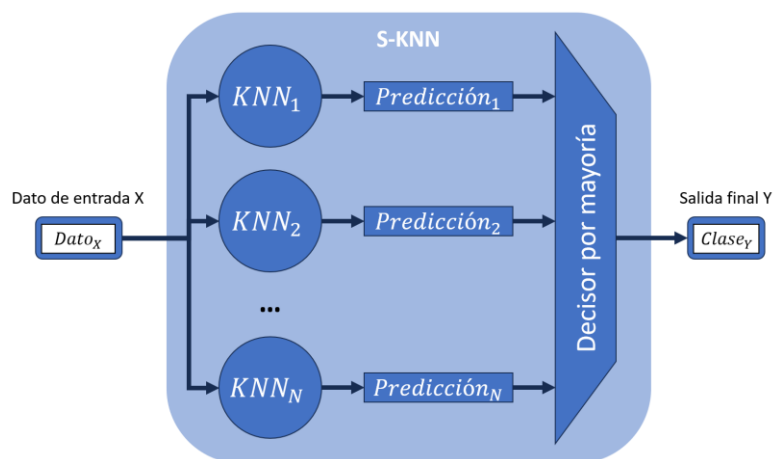


Figura 3.11. Esquema general de la fase de clasificación de un sistema S-KNN.

3.3.3. RESULTADOS

En este apartado se presentan los mapas de batimetría obtenidos en este TFM. Los mapas de batimetría se han generado aplicando los modelos SBM y S-KNN en la imagen multispectral WV-2 y aplicando SBM a la imagen hiperespectral Pika L, ambas imágenes capturadas en la zona de estudio de El Río. De esta manera, se pretende realizar un estudio de los resultados entre algoritmos y plataformas.

Para la evaluación de la calidad de los mapas obtenidos, se aplica el coeficiente de determinación R^2 , la Raíz del Error Cuadrático Medio ($RMSE$) y el Error Absoluto Medio (MAE), expresados según las ecuaciones:

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}^{(i)} - \bar{y})^2}{\sum_{i=1}^N (y^{(i)} - \bar{y})^2}, \quad (3.5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{y}^{(i)} - y^{(i)})^2}{N}}, \quad (3.6)$$

$$MAE = \frac{\sum_{i=1}^N |\hat{y}^{(i)} - \bar{y}|}{N}, \quad (3.7)$$

donde N representa el número de muestras, $\hat{y}^{(i)}$ representa la salida estimada de la muestra i , \bar{y} representa el valor medio de las salidas esperadas, e $y^{(i)}$ representa la salida esperada de la muestra i .

El coeficiente R^2 permite conocer la robustez y calidad del modelo. El $RMSE$ indica el error cuadrático promedio en metros de la batimetría obtenida. Por último, el MAE indica el error absoluto promedio.

Como se ha expuesto anteriormente, para utilizar algoritmos de clasificación, tanto modelos físicos empíricos como basados en *Machine Learning*, es necesario disponer de datos de entrenamiento. En el caso de la batimetría, se requiere de una batimetría de referencia de la que se obtienen dichos datos. La Figura 3.12 muestra la batimetría de referencia en forma de isobatas, de 1 m de resolución, sobre la imagen WV-2 de la zona de El Río. Para poder introducir correctamente esta información en la generación de mapas, se debe asegurar que la corrección de la georreferencia se ha realizado correctamente en el preprocesado. En caso contrario, la referencia no coincidiría con la imagen a procesar y, por lo tanto, el mapa de batimetría obtenido no sería válido.




Figura 3.12. Batimetría de referencia en forma de isobatas y resolución de 1m sobre imagen WV-2 de El Río.

▪ BATIMETRÍA SATELITAL MULTIESPECTRAL WV-2

A continuación, se muestra los mapas de batimetría obtenidos al aplicar el modelo SBM y S-KNN a la imagen preprocesada WV-2 utilizando diferentes zonas de la batimetría de referencia para entrenar los modelos. El sistema S-KNN utilizado en este TFM está formado por siete modelos KNN.

Para exponer los resultados, se ha limitado la profundidad a 15 m, punto donde se establecen las zonas de aguas profundas y se representan en el mismo color. Además, la clasificación de la profundidad se realiza píxel a píxel con una resolución de 1 m, dado por la referencia. Finalmente, para suprimir el ruido, se aplica un filtro gaussiano de tamaño 5x5 píxeles. El tamaño del filtro permite reducir el ruido sin suavizar en exceso la información de batimetría.

En la Figura 3.13 se presentan los resultados obtenidos de aplicar SBM y S-KNN a la imagen satelital WV-2. De manera cualitativa, los mapas generados con SBM disponen de mayor calidad y semejanza respecto a la referencia de manera general. Sin embargo, en las zonas más cercanas a la costa presenta errores en mayor medida que los producidos por S-KNN. Para la generación de estos mapas, se han entrenado los modelos con la mayor cantidad de información de referencia posible, con el fin de presentar unos mapas de mejor calidad.

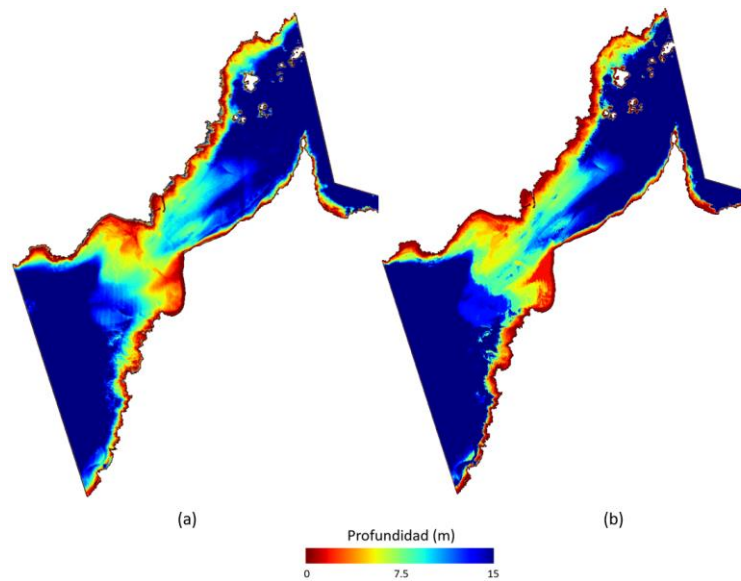


Figura 3.13. Mapas de batimetría con datos de entrenamiento completos de El Río con imagen satelital WV-2: (a) Modelo SBM, (b) Modelo S-KNN.

El ajuste de la sigmoide al generar el mapa de batimetría mediante SBM se presenta en la Figura 3.14. El modelo Sigmoide también se puede comportar de forma lineal coincidiendo con el modelo Stumpf, ya que la función sigmoide dispone de una parte lineal. Esta es una muy buena característica del modelo, ya que se comporta como Stumpf añadiendo al modelo el comportamiento no lineal de los datos en aguas profundas. En este caso, existe linealidad y el modelo Sigmoide se ajusta correctamente a los datos.




Figura 3.14. Ajuste del modelo SBM a los datos de la imagen satelital WV-2.

La Tabla 3.1 muestra las métricas de error calculadas en la generación de los mapas de batimetría según el modelo utilizado, con el fin de realizar un estudio cuantitativo de la calidad de cada método aplicado a la imagen WV-2.

Tabla 3.1. Métricas de error de los mapas de batimetría con la imagen WV-2 de El Río.

MODELO	$R^2 \uparrow$	$RMSE \downarrow$	$MAE \downarrow$
SBM	0,63	5,20 m	3,65 m
S-KNN	0,85	3,48 m	2,13 m

Respecto al estudio cuantitativo, se puede remarcar que S-KNN presenta generalmente errores inferiores que el modelo SBM, específicamente en los mapas entrenados con el conjunto completo de datos. Aun teniendo mejor calidad en el mapa, los errores introducidos en las zonas más costeras y nubes establecen una gran diferencia entre la referencia y la profundidad que presenta los píxeles de las zonas en cuestión.

▪ BATIMETRÍA DRON HIPERESPECTRAL PIKA L

La Figura 3.15 muestra los mapas de batimetría generados mediante SBM y S-KNN de la imagen dron hiperespectral Pika L. De manera cualitativa, el mapa generado con SBM presenta mayor calidad en general que el mapa obtenido con S-KNN. No obstante, se pueden observar errores graves en la parte inferior de la imagen. La batimetría producida por el modelo S-KNN no dispone tantos errores en la parte inferior de la imagen, pero en la zona superior, correspondiente a agua poco profundas, presenta un error notorio resaltado por el bandeo de la imagen.

Los resultados obtenidos con la imagen Pika L disponen de una resolución mucho mayor y un mapa más detallado que el generado con la imagen WV-2. Sin embargo, el bandeo presente en la captura de la imagen altera el resultado. Especialmente, en la parte inferior de la imagen, resaltan unos píxeles rojos, indicando agua poco profunda. No obstante, en estos píxeles se debería disponer de una profundidad superior a la presentada. Esto se debe a que existe una diferencia temporal entre la captura de la parte superior de la imagen y la inferior. El desajuste temporal implica cambios en la radiancia capturada por el sensor debido al movimiento del sol. Por ello, el algoritmo interpreta la radiancia recibida como una zona de menor profundidad al compararlo con el resto de la imagen.




Figura 3.15. Mapa de batimetría de El Río con la imagen dron Pika L obtenido mediante: (a) SBM y (b) S-KNN.

En la Figura 3.16 se presenta el ajuste del modelo Sigmoide a los datos de la imagen dron Pika L. En este caso, también existe linealidad en los datos y SBM se ajusta correctamente. Además, se puede observar un mayor ruido respecto a la imagen WV-2. Esto se puede deber al bandeo descrito anteriormente, que introduce una mayor varianza a los datos.




Figura 3.16. Ajuste del modelo SBM a los datos de la imagen dron Pika L.

La Tabla 3.2 muestra las métricas de error obtenidas en los mapas generados con la imagen dron Pika L y los mapas de la imagen satelital WV-2. El coeficiente R^2 de las imágenes Pika L presenta unos valores similares a las imágenes WV-2. Sin embargo, la mayor diferencia se refleja en los $RMSE$ y MAE , donde se reduce el error en las imágenes Pika L. Estos resultados muestran que los mapas Pika L son más precisos. Específicamente, el modelo S-KNN muestra mejores métricas de error, al igual que en la imagen WV-2, aun presentado un mapa peor en términos cualitativos.

Tabla 3.2. Comparación de las métricas de error de los mapas de batimetría con la imagen WV-2 y Pika L de El Río.

IMAGEN	MODELO	$R^2 \uparrow$	$RMSE \downarrow$	$MAE \downarrow$
WV-2	SBM	0,63	5,20 m	3,65 m
	S-KNN	0,85	3,48 m	2,13 m
PIKA L	SBM	0,73	2,83 m	2,15 m
	S-KNN	0,83	2,26 m	1,26 m

La Figura 3.17 muestra el resultado WV-2 de la batimetría en la zona de la imagen Pika L. Además, se puede apreciar con la línea gris la diferencia de tamaño entre la imagen Pika L y la imagen WV-2. Al comparar este resultado con el mapa Pika L, se puede observar un menor detalle y resolución. Sin embargo, la calidad general de la profundidad a esta escala es similar, especialmente en la obtenida mediante SBM, aun cubriendo un área mucho más extensa. Con esta comparación se pretende destacar el valor de las imágenes WV-2 para obtener mapas de batimetría en aplicaciones generales.

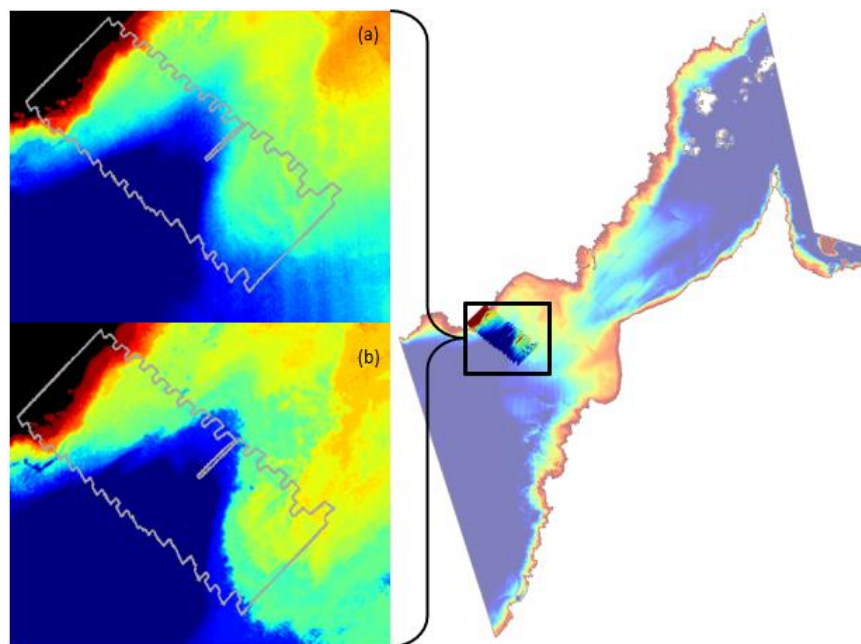


Figura 3.17. Comparativa de los mapas de batimetría (a) SBM y (b) S-KNN en la zona de vuelo dron.

3.4. HÁBITATS BENTÓNICOS

En los últimos años, el uso de la teledetección para la generación de mapas de hábitats bentónicos o de tipos de fondos marinos ha servido de gran apoyo en la monitorización de los ecosistemas marinos, para identificar las comunidades vegetales en la zona de estudio y evaluar los cambios en la propia topografía marina [12], [44].

Sin embargo, el entorno marino para la obtención de mapas de hábitats bentónicos presenta ciertas limitaciones. Las imágenes satelitales utilizadas para generar mapas de hábitats bentónicos se capturan desde sensores situados a cientos de kilómetros de la superficie, donde las condiciones de la superficie marina y la atmósfera cobran mayor relevancia. Para conseguir información válida mediante teledetección, es necesaria una superficie marina calmada y que no presente signos de turbidez para que la radiancia pueda penetrar la columna de agua correctamente.

Por otro lado, el lecho marino presenta una gran variedad de tipos de sustratos y comunidades vegetales. Sin embargo, únicamente se podrán identificar aquellas comunidades bentónicas que se extiendan con un tamaño considerable respecto a la resolución espacial del sensor. Además, la discriminación de estas comunidades depende a su vez de la variabilidad en la reflectividad que tengan entre sí, especialmente en las bandas espectrales que presentan mayor penetración en el agua.

Para superar los efectos que intervienen en la captura de información, se debe hacer un uso cuidadoso del procesado y clasificación. Para el procesado, se requiere del uso de técnicas avanzadas y complejas que permitan minimizar el efecto de las limitaciones comentadas, como son los modelos basados en *Machine Learning*. Cabe destacar de estas técnicas, aparte de su carga computacional, que se debe disponer de datos de entrenamiento de la zona de estudio. Por ello, es necesario disponer de datos de medidas *in-situ* validadas por biólogos marinos. La obtención de esta información puede suponer un despliegue de efectivos costoso si se necesita cubrir un área muy extensa.

Adicionalmente, un estudio temporal puede otorgar una visión general de la evolución del lecho marino a lo largo de años, ayudando a identificar los cambios en el fondo marino en el tiempo entre las medidas *in-situ* y la captura de las imágenes. Además, ayuda a definir la campaña de datos *i-situ* si no se disponen de datos previos o estos no presentan la calidad suficiente.

La Figura 3.18 muestra el esquema general de la metodología aplicada en este TFM para la generación de mapas de hábitats bentónicos. Inicialmente, se parte con una imagen preprocesada siguiendo las correcciones descritas anteriormente. La generación de estos mapas se basa en un

modelo *Machine Learning*, que depende de datos de entrenamiento. Para la obtención de estos datos, se ha realizado un estudio de la variabilidad del fondo marino de El Río durante los últimos años con imágenes Sentinel-2. A partir de esta información, se realizó una campaña de campo para obtener los datos de entrenamiento. Partiendo de las medidas *in-situ*, se definen las regiones de interés (*Region of interest, ROI*) de los diferentes fondos marinos o clases, que servirán de referencia para entrenar el modelo *Machine Learning*. Finalmente, se estima el mapa de hábitats bentónico con la totalidad de la imagen y se realiza una evaluación cualitativa, según la observación del resultado, y cuantitativa, con apoyo de las métricas de error. Este proceso se realiza para la imagen satelital WV-2 y dron Pika L con el objetivo de realizar un estudio multiplataforma.

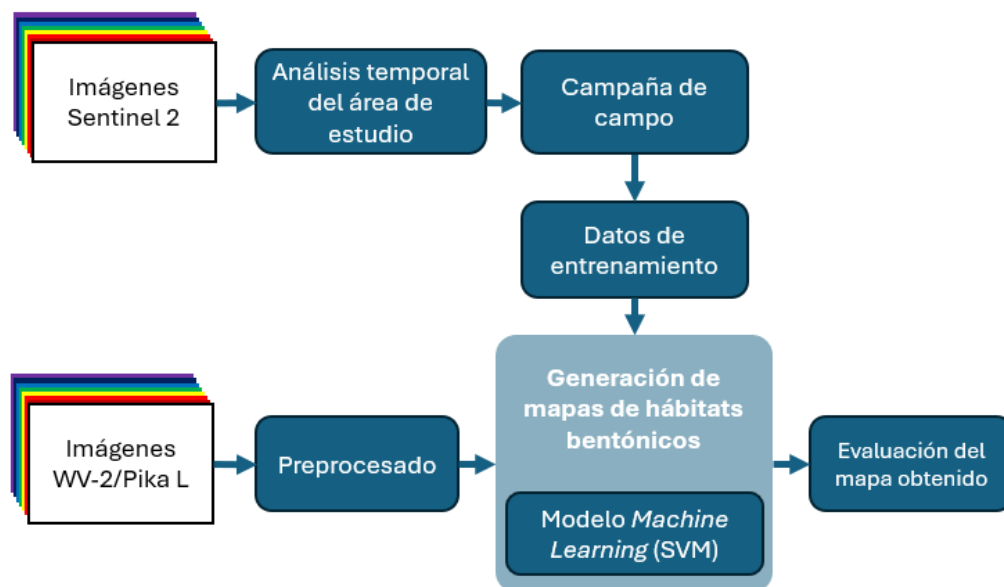


Figura 3.18. Metodología utilizada para la obtención de mapas de hábitats bentónicos.

En este apartado, se describe la evaluación temporal de El Río mediante productos Sentinel 2. Adicionalmente, se explica el modelo *Machine Learning, Support Vector Machine*, utilizado para obtener los mapas de hábitats bentónicos. Finalmente, se realiza un análisis de los resultados, explicando la obtención de las ROIs y comparando los mapas obtenidos con las imágenes satelital WV-2 y dron Pika L.

3.4.1. EVOLUCIÓN TEMPORAL CON IMÁGENES SENTINEL-2

Las praderas de *Cymodocea nodosa*, localmente llamadas seabadales, forman parte de los ecosistemas más importantes de los fondos marinos canarios [45]. Concretamente, tienen una presencia notoria en El Río [14]. No obstante, los seabadales han ido disminuyendo con el paso de los años. En la Figura 3.19 se muestra las zonas pobladas con seabadales en las aguas entre Lanzarote

y La Graciosa dentro de la ZEC. Según los estudios realizados en las aguas costeras de la zona [46], en 2001 las praderas de sebadal ocupaban un área de 505 Ha. Sin embargo, en 2010, se había reducido el área total un 81%, dejando una extensión total de 96 Ha.




Figura 3.19. Estudio en un mapa de las zonas de sebadal en el Río en los años 1997, 2001 y 2010 [46].

Realizar un estudio completo sobre la evolución a lo largo del tiempo de una zona geográfica específica es una tarea costosa con métodos convencionales, debido a la cantidad de medios necesarios para poder conseguir información precisa. A pesar de ello, la teledetección ayuda a disminuir el coste de estos estudios. En concreto, los productos generados por el programa Copernicus permiten obtener imágenes gratuitas con una resolución temporal adecuada en la monitorización de las comunidades y fondos marinos. Para llevar a cabo este análisis, se han seleccionado productos del nivel 2A entre los años 2018 y 2023.

Para el estudio interanual se han elegido los productos Sentinel de la última semana de noviembre. La elección de la fecha para el análisis entre años se ha ajustado a varios aspectos importantes. Principalmente, los productos en estas fechas presentan unas condiciones meteorológicas óptimas para su uso. Es decir, no hay nubes que oculten la superficie marina y no hay oleaje que enturbie las aguas costeras. Además, elegir la misma fecha entre las imágenes evita errores en la estacionalidad de las especies, permitiendo obtener conclusiones válidas. La Figura 3.20 muestra las imágenes Sentinel anuales de El Río seleccionadas para este caso. Por otro lado, en la Figura 3.21 se presenta un recorte de la zona con mayor concentración de sebadal.




Figura 3.20. Estudio temporal de El Río con imágenes Sentinel-2.




Figura 3.21. Estudio temporal de El Río, centrado en las zonas de sebadal con imágenes Sentinel-2.

Al estudiar las zonas de sebadal, se puede observar un incremento en la población de la comunidad que aparece en el fondo marino. Una posible respuesta a este comportamiento podría ser que el sebadal se haya ido recuperando gradualmente en los últimos años. Sin embargo, el impacto antrópico y el deterioro por las corrientes marinas de la zona no favorecen el crecimiento de sebadal. Además, en las últimas décadas ha habido un descenso de la productividad de las especies bentónicas [46] que ha facilitado la proliferación de especies de algas invasoras. Por ello, es posible concluir que el aumento de la población en esta área no sea un incremento de sebadal, sino la presencia de otra especie a la que le hayan favorecido estos cambios. Esta posibilidad genera la necesidad de realizar un estudio en profundidad de la zona.

Tras el estudio de la zona de interés, se ha hecho uso del modelo de clasificación SVM de las imágenes WV-2 y Pika L disponibles para este TFM. Gracias a las mejoras de resolución en estas imágenes respecto a los productos Sentinel, se puede realizar un estudio más exhaustivo de los tipos de sustratos y comunidades vegetales que se encuentran en el fondo de El Río y comprobar el estado del sebadal. Además, este análisis ha permitido estimar los puntos de interés para la obtención de las ROIs que entrenan al algoritmo que se explica a continuación.

3.4.2. SUPPORT VECTOR MACHINE (SVM)

Support Vector Machine [47] es una técnica de clasificación *Machine Learning* basada en dividir el espacio de características entre clases mediante hiperplanos. La Figura 3.22 muestra un ejemplo de la evolución de un sistema de clasificación SVM entre dos clases. Inicialmente, los datos se encuentran sin clasificar sobre el espacio de características. En este caso, la clasificación consiste en dividir el espacio para limitar las distintas clases utilizando un hiperplano que las separe. Para escoger este hiperplano, se tienen en cuenta dos criterios. En primer lugar, se pretende minimizar la distancia de todos los puntos respecto al posible hiperplano. Esta minimización se consigue con la distancia normal entre los puntos y el umbral. Sin embargo, existen infinitos hiperplanos que satisfacen este criterio. En segundo lugar, se establece un margen o frontera de decisión a partir del hiperplano, con el fin de identificar el hiperplano que presente mayor margen. Con el hiperplano definido, se separa de manera óptima el espacio y al aparecer un dato nuevo de entrada, según su posición, se determina la clase a la que pertenece.

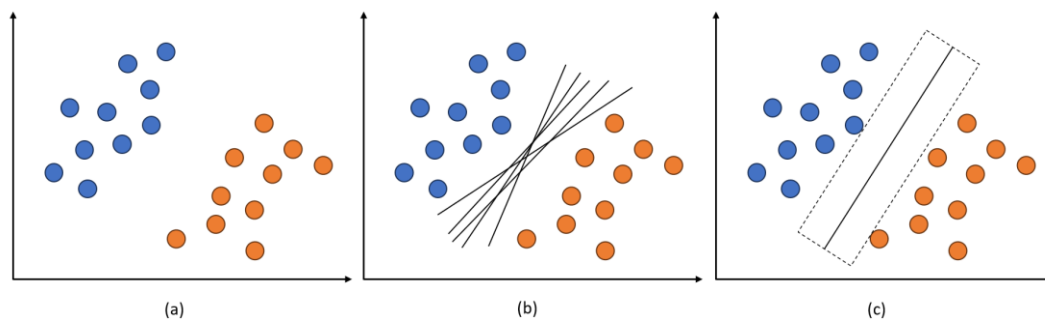


Figura 3.22. Clasificación SVM entre dos clases: (a) espacio de características bidimensional con dos clases libres, (b) existen infinitos hiperplanos posibles que separen ambas clases y, (c) se determina el hiperplano óptimo que mantiene el margen máximo entre las clases.

El modelo SVM que se ha comentado es lineal y clasifica entre dos clases. Para la clasificación de más clases, se puede aplicar SVM repetidamente. Primero, se divide el espacio de características utilizando SVM entre clases y obteniendo dos subespacios. A partir de los subespacios obtenidos se emplea de nuevo SVM, repitiendo el proceso las veces necesarias hasta separar el espacio en función del número de clases. La división del espacio en cada iteración se puede hacer entre dos clases o de una clase respecto al resto.

Además, en ocasiones no es posible separar linealmente las clases en un espacio de características. Para realizar su clasificación mediante SVM, se hace uso de un *kernel*, que permiten linealizar el espacio de características aplicando una función no lineal a cada uno de los puntos del espacio. La Figura 3.23 muestra un ejemplo de clasificación SVM mediante un *kernel* gaussiano. Este *kernel* es uno de los más comunes para clasificación SVM no lineal.

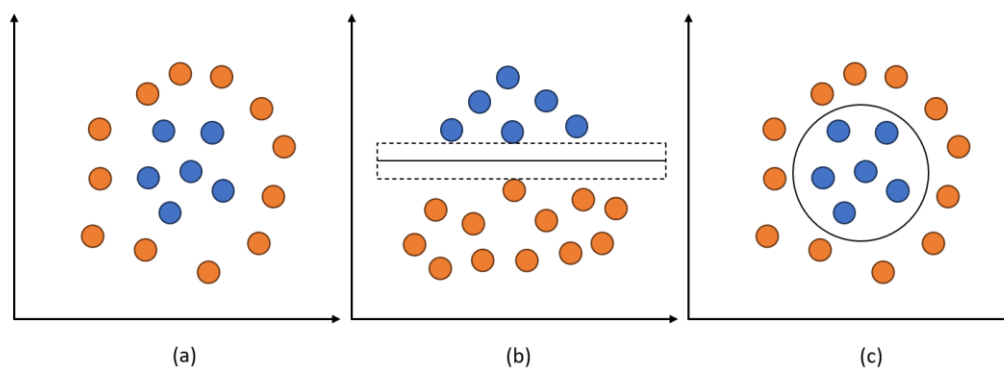


Figura 3.23. Clasificación SVM entre dos clases mediante *kernel* gaussiano: (a) espacio de características con dos clases que no permiten ser separadas linealmente, (b) cambio en el espacio de características mediante *kernel* gaussiano y división de las clases mediante hiperplano y, (c) vista de la clasificación SVM en el espacio de características original.

3.4.3. RESULTADOS

En este apartado se presentan los resultados obtenidos de la generación de mapas de hábitats bentónicos, con la metodología anteriormente explicada. Al igual que para la batimetría, se ha hecho uso de la imagen multiespectral satelital WV-2 y la imagen hiperespectral dron Pika L de la zona de El Río.

Para poder emplear SVM en la generación de mapas, se requiere de datos de entrenamiento de la zona de estudio. Esta información se ha obtenido en una campaña de campo realizada en el Río el día 29 de octubre de 2023 por un equipo de biólogos marinos. Para la adquisición de los datos, en primer lugar, se establecieron geográficamente los puntos de interés que se querían estudiar, con el fin de identificar las especies o estratos que componen la heterogeneidad del fondo marino. Con esta información, el proceso de recogida de datos consistió en aproximarse a las coordenadas establecidas en cada punto a bordo de una embarcación y sumergir una cámara hasta el fondo marino para filmar el fondo marino. De esta manera, se consiguen imágenes que permiten identificar el tipo de fondo en los puntos de interés.

La Figura 3.24 muestra la posición geográfica de cada una de las verificaciones propuestas para el estudio y las verificaciones finalmente realizadas durante la campaña. En total, se identificaron 78 puntos con información precisa del tipo de sustrato y comunidades vegetales del fondo marino de El Río.




Figura 3.24. Puntos propuestos y capturados del fondo marino en la zona de El Río.

Según la campaña de campo, el fondo marino de El Río está compuesto por diferentes tipos de sustratos y comunidades vegetales. Los tipos de fondo o clases se han agrupado de la siguiente manera:

- **Roca:** formado por sustratos como pedregales, plataformas rocosas, sedimentos y rocas sin presencia de vegetación.
- **Arena:** agrupación de fondos arenosos sin presencia de vegetación.
- **Algas:** formado por comunidades vegetales de menor interés como algas rojas filamentosas, algas verdes y algas pardas.
- **Sebadal:** grupo de mayor interés en este TFM formado por puntos con presencia vegetal de sebadal y *Caulerpa prolifera*.

La Figura 3.25 muestra las ROIs obtenidos de la clasificación de cada uno de los puntos de estudio según las clases comentadas. De esta manera, se dispone de información previa para entrenar el modelo SVM y generar los mapas de hábitats bentónicos deseados.




Figura 3.25. ROIs obtenidos del área de estudio de El Río.

Tras obtener las ROIs para la clasificación, se realizó un estudio de la separabilidad de las clases. En este caso, se obtienen las firmas espectrales de cada clase y se evalúa su similitud. La Figura 3.26 muestra la firma espectral de las clases Roca (marrón), Arena (amarillo), Algas (rojo) y Sebadal (verde). Se puede observar como la clase Roca presenta mayor separabilidad respecto al resto. Sin embargo, las otras tres clases disponen de una firma espectral muy similar, lo que puede resultar un problema para clasificar la imagen correctamente.

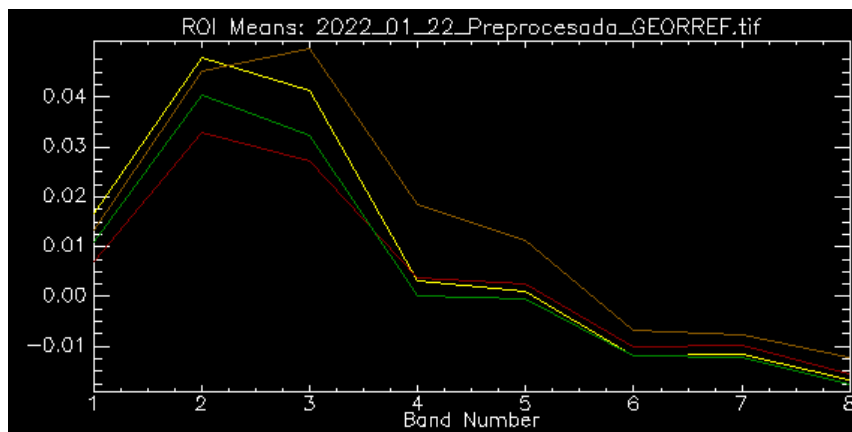


Figura 3.26. Firmas espectrales de las clases Roca (marrón), Arena (amarillo), Algas (rojo) y Sebadal (verde).

▪ IMAGEN SATELITAL MULTIESPECTRAL WV-2

Con estas ROI, se ha utilizado SVM para generar un mapa de hábitats bentónicos y clasificar el fondo marino de El Río. La Figura 3.27 muestra la imagen original WV-2 y el mapa de hábitats bentónicos obtenido. En esta clasificación, se establecieron las zonas de aguas profundas como una clase extra que se representa en negro en el mapa. De este mapa, se pudo analizar que la escasa separabilidad entre clases provoca que disminuya la calidad del resultado. Las zonas que clarifican el error en la clasificación son las extensiones de sebadal donde debería haber arena o algas en la zona central de la imagen, así como la sobreestimación de las zonas profundas en las zonas superior e inferior de la imagen.




Figura 3.27. Clasificación del fondo marino mediante SVM: (a) imagen preprocesada WV-2 de El Río, (b) Mapa de hábitats bentónicos obtenido al clasificar la imagen completa.

A la vista del resultado obtenido, se comprobó la complejidad de clasificar correctamente el fondo marino de la zona de estudio con la imagen WV-2. Por ello, se han realizado ciertos cambios en la imagen y la clasificación. En primer lugar, se realizó la clasificación de las clases con firmas espectrales muy similares de manera individualizada. Específicamente, se realizó la clasificación del fondo eliminando la clase Sebadal y se clasificó el fondo enfrentando únicamente las clases Sebadal y Arena para, posteriormente, unir ambos resultados.

La Figura 3.28 muestra los mapas obtenidos mediante SVM en cada uno de los casos comentados anteriormente. El objetivo de generar ambos mapas consistía en capturar las zonas más problemáticas correspondientes al sebadal y superponer esa información en el mapa con el resto de clases. De esta manera, se consigue mejorar la clasificación de la clase que presentaba mayores errores en la primera aproximación.




Figura 3.28. Mapas de hábitats bentónicos: (a) sin la clase Sebadal y, (b) con la clase Sebadal y Arena, únicamente.

En la Figura 3.29 se presenta la comparación de las zonas de sebadales entre la imagen original WV-2 y los mapas generados. Se puede observar que la primera clasificación tiene un error considerable en la clasificación del sebadal, especialmente en la zona inferior de la imagen, mientras que la clasificación individual de esta especie mejora considerablemente. Esta mejora se refleja centrando la comparación en las zonas de sebadal reales, según las ROI, representadas con un recuadro verde.

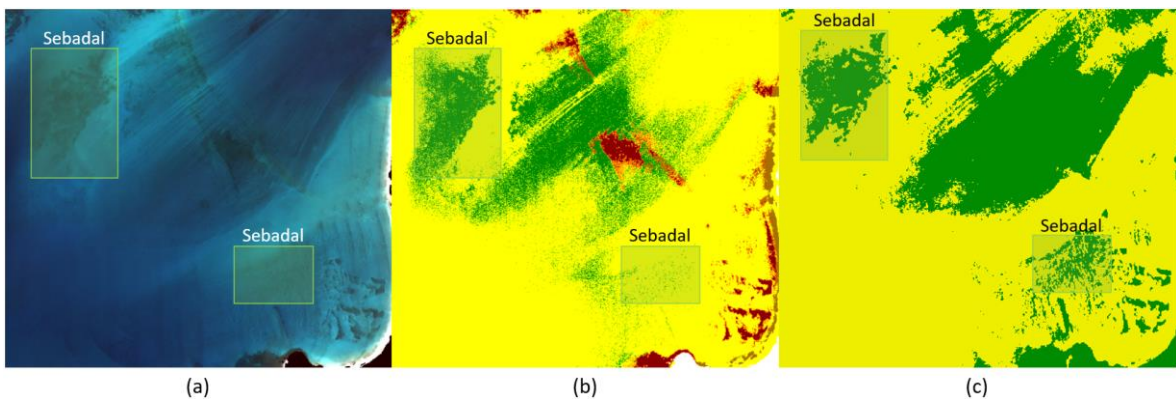


Figura 3.29. Zonas de sebadales reales, según ROI: (a) en la imagen preprocesada WV-2, (b) en la clasificación de la imagen completa con SVM y (c) en la clasificación de la clase Sebadal y Arena mediante SVM.

El siguiente cambio consistió en corregir la segunda fuente de error notable en la primera clasificación, las zonas de aguas profundas. Para ello, se recortó la imagen para centrarla en la zona de mayor interés, donde se encontraban las ROI. Además, se utilizó la batimetría de referencia para enmascarar el agua profunda en 15 m para realizar la clasificación. Esta medida se toma ya que, a partir de dicha profundidad, se puede considerar que la radiancia se dispersa en el medio, provocando que los valores obtenidos correspondan a ruido de dispersión y no realmente al fondo marino.

La Figura 3.30 muestra el mapa de hábitats bentónicos de El Río tras la superposición de la clase Sebadal y centrando la imagen a la zona de interés para el estudio del fondo marino. Se puede observar en este mapa una mayor coherencia en la clasificación respecto a la clasificación utilizando todas las clases.




Figura 3.30. Mapa de hábitats bentónicos mediante SVM con la imagen WV-2 de El Río.

Con el mapa generado, se pueden obtener las métricas de error. En el caso de los mapas de hábitats bentónicos, se ha considerado la precisión global y la precisión de cada una de las clases. La precisión viene dada por la siguiente ecuación:

$$Precisión = \frac{TP}{TP + FN}, \quad (3.8)$$

donde TP son los verdaderos positivos, correspondientes al número de veces donde la clasificación de un píxel coincide con la clase esperada; y los FN son los falsos negativos, correspondientes al número de casos donde se clasifica la entrada como una clase no esperada.

La Tabla 3.3 muestra las precisiones de cada clase y global del mapa de hábitats bentónicos obtenido. Estas métricas se obtienen utilizando el 20% de la información de las ROIs, ya que el 80% corresponde al entrenamiento del modelo SVM. Esta distribución de los datos se ha basado en la poca información de referencia disponible. Se puede observar que la clase Roca presenta la menor precisión. Esto se debe a las pocas ROI de esta clase y a que los sustratos rocosos se pueden confundir con la arena y albergan distintas algas que alteran el resultado de la clasificación. Por otro lado, la clase Sebadal se ha clasificado correctamente en las zonas donde la población se concentra en mayor medida, siendo clasificado como arena el sebadal separado de estas praderas. La clase Arena presenta buenos resultados en la clasificación. Sin embargo, presenta problemas similares a

la clase Roca en las zonas donde habitan las algas. Por último, la clase Alga presenta los mejores resultados en la clasificación.

Tabla 3.3. Precisión de cada clase y global del mapa de hábitats bentónicos.

Clase	Precisión
1. Roca	50 %
2. Arena	85,71 %
3. Algas	96,77 %
4. Sebadal	63,16 %
GLOBAL	73,91 %

Finalmente, en la Figura 3.31 se actualiza la tendencia temporal de la población de sebadales en El Río, respecto al estudio descrito anteriormente, añadiendo los resultados de este TFM. Según los resultados, se puede observar como la extensión de sebadal se ha visto reducida a una ínfima parte de su extensión en 2001.

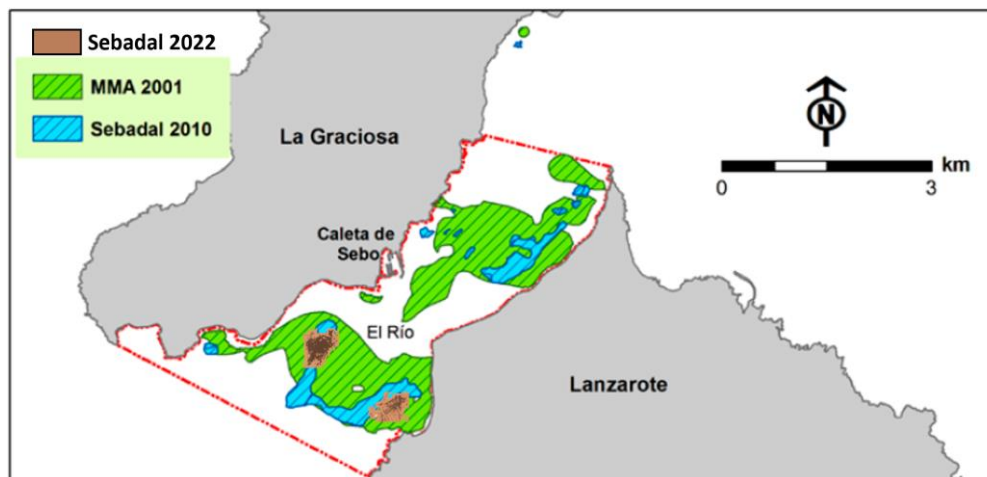


Figura 3.31. Estudio de la evolución del sebadal en El Río con la información del mapa de hábitats bentónicos obtenido.

▪ IMAGEN DRON HIPERESPECTRAL PIKA L

La Figura 3.32 muestra el mapa de hábitats bentónicos obtenido mediante SVM. La imagen se ha recortado mínimamente para mejorar su presentación. Cabe destacar que, gracias a la gran mejoría en resolución espacial y espectral de la imagen dron, no ha sido necesario dividir la clasificación de las clases conflictivas y se ha generado el mapa directamente sin modificaciones adicionales. Además, este mapa presenta una clasificación con un 100% de precisión en cada una de las clases. Esto es debido a que los datos de entrenamiento y test de cada clase son similares por los pocos

puntos de verificaciones disponibles en el área del vuelo dron. Sin embargo, esta precisión no garantiza que el mapa generado sea perfecto. Cualitativamente, se puede observar, en la parte superior de la imagen, ciertos errores que la clasificación entre las clases Roca, Arena y Algas. Además, en la parte inferior se puede apreciar la influencia del bandeo en la captura de la imagen y errores por sobreestimación de la clase Sebadal frente a la Arena.




Figura 3.32. Mapa de hábitats bentónicos mediante SVM con la imagen Pika L de El Río.

En este mapa obtenido con la imagen Pika L, el detalle del fondo marino es mucho mayor que en el mapa WV-2. Este hecho justifica el uso de imágenes dron hiperespectrales especialmente en zonas complejas de clasificar, como en este caso, ya que las resoluciones espacial y espectral de esta imagen permite obtener resultados óptimos de las zonas más conflictivas. Además, obtener información del fondo marino con este nivel de detalle y precisión justifica a su vez el coste de la imagen dron hiperespectral en esta área de estudio.

3.5. RESUMEN

En este capítulo inicialmente se han descrito las metodologías empleadas en este TFM para la monitorización marina de El Río. Posteriormente, se ha explicado los preprocesados específicos de aplicaciones marinas, junto al modelo físico y las técnicas basada en ML para la obtención de mapas de batimetría y hábitats bentónicos. Además, se han presentado los resultados del preprocesado, batimetría y clasificación del fondo marino.

Respecto a la batimetría, la imagen WV-2 permite generar un mapa completo de la zona de El Río con una notable precisión y robustez a muy alta resolución, aportando un resultado muy útil para la mayoría de las aplicaciones que requieran de estos mapas. Por otro lado, la imagen Pika L aporta un mapa de mayor resolución y fiabilidad, pero reducido a la zona de vuelo. De esta manera,

la imagen WV-2 se presenta como la opción más razonable para obtener mapas de batimetría por la relación entre la calidad del mapa y la cantidad de información que ofrece. Mientras, la imagen Pika L permite generar mapas para aplicaciones más específicas en los que se requiera de una máxima precisión de una zona muy reducida.

Respecto a los hábitats bentónicos, el estudio realizado con imágenes satelitales otorga una visión general de la zona de estudio, que ha permitido analizar la situación del fondo marino de El Río y establecer los puntos para la generación de las ROIs y generación de los mapas. De los resultados obtenidos, destaca la complejidad en la clasificación del fondo marino por la similitud en las firmas espectrales de las clases. La imagen WV-2 requiere de procesos adicionales para generar un mapa coherente de los hábitats bentónicos, aunque el resultado final presenta una calidad notable. Finalmente, se destaca la imagen Pika L como la mejor opción en la obtención de mapas de hábitats bentónicos, ya que permite separar mejor las clases y otorga al mapa mayor precisión, gracias a la resolución espectral. Por último, cabe destacar que El Río se presenta como una zona muy compleja para la clasificación de su fondo marino.

En el próximo capítulo se expone la metodología para la caracterización del área de estudio terrestre, dentro del Parque Nacional de Timanfaya. Inicialmente se presentará la zona de estudio y, posteriormente, se desarrollarán los métodos empleados para generar los mapas mediante tecnología LiDAR y multiespectral. Finalmente, se exponen los resultados obtenidos.

Capítulo 4: MONITORIZACIÓN TERRESTRE: CARACTERIZACIÓN DEL SUELO DEL PARQUE NACIONAL DE TIMANFAYA

En los capítulos precedentes, y en el marco de los trabajos desarrollados en este TFM, se han descrito las metodologías y se han mostrado los resultados de la monitorización de zonas costeras mediante imágenes multiespectrales e hiperespectral. El otro aspecto que se estudia en este TFM es la monitorización de espacios protegidos utilizando nubes de puntos LiDAR e imagen multiespectral para clasificar la superficie terrestre e identificar vegetación.

El área de estudio seleccionado para la monitorización terrestre se encuentra en el interior del Parque Nacional de Timanfaya [48], que se muestra en la Figura 4.1. Timanfaya se declaró Parque Nacional en 1974 y alcanza una extensión de 5.107,5 hectáreas. A pesar de sus condiciones climatológicas con bajas precipitaciones, dispone de una relevante riqueza biológica, así como numerosos endemismos vegetales y animales.



Figura 4.1. Parque Nacional de Timanfaya, en la isla de Lanzarote, Canarias.

En los últimos años, el Parque Nacional de Timanfaya se está viendo afectado por la aparición de especies vegetales invasoras [18]. Entre estas especies, destaca la vinagrera o calcosa (*Rumex lunaria*). Aunque se ha intentado su eliminación, la vinagrera presenta una alta regeneración que hace imposible su erradicación. Esto ha provocado que la administración del Parque haya llevado a cabo un aislamiento de la especie en las zonas ya afectadas. Por ello, surge la necesidad de establecer un control permanente de la población de las vinagreras y su expansión en Timanfaya. La Figura 4.2 muestra la extensión del Parque Nacional de Timanfaya, resaltando el área de estudio de este TFM, que posee una gran concentración de vinagreras.



Figura 4.2. Extensión del Parque Nacional de Timanfaya y ubicación del área de estudio.

Para llevar a cabo la caracterización del suelo del área de estudio, se pretende utilizar tecnología LiDAR y multiespectral capturadas desde un dron con ambos sensores. El objetivo consiste en obtener datos relevantes para la clasificación de la vegetación, como la altura de la vegetación mediante LiDAR o la reflectividad de la clorofila mediante la imagen multiespectral.

En este TFM, para clasificar la vegetación, se utilizan los productos del área de estudio enumerados a continuación:

1. **Nube de puntos LiDAR Zenmuse L1 del 2 de noviembre de 2023**, con una resolución espacial de 10 cm entre puntos, Con esta nube de puntos, se pretende realizar la caracterización del suelo del área de estudio.
2. **Imagen multiespectral MicaSense Dual del 2 de noviembre de 2023**, como fuente para la generación del mapa de caracterización del suelo, aportando información adicional y diferente del área de estudio.

Los productos descritos se presentan en la Figura 4.3. Las imágenes se capturaron durante el mismo vuelo dron, que volaba con ambos sensores.



Figura 4.3. Productos de Timanfaya del 02/11/2023 para la monitorización terrestre: (a) nube de puntos LiDAR Zenmuse L1 con coloración RGB, (b) imagen multiespectral MicaSense Dual.

Cada producto presenta información diferente del área de estudio, por lo que su procesamiento no es idéntico. En la Figura 4.4 se muestra el esquema general de la metodología para la caracterización del suelo en el área de estudio, que se divide en los dos productos disponibles.

Respecto a la nube de puntos LiDAR, inicialmente, se realiza el preprocesado de los datos. El primer paso consiste en clasificar los puntos correspondientes al terreno. En función de esta clasificación, se puede obtener el modelo digital del terreno (MDT), el modelo digital de superficie (MDS) y el modelo de altura del dosel (*Canopy Height Model*, CHM). A partir de los datos preprocesados, se caracteriza el suelo clasificando la vegetación sobre la nube de puntos. Esta clasificación se realiza según la altura, o según la altura y el radio de las agrupaciones de puntos similares. Finalmente, se analizan los resultados obtenidos.

Por otra parte, respecto a la imagen multiespectral MicaSense, inicialmente se generan índices de vegetación. A partir de esta información, se obtiene el histograma de la imagen para decidir el umbral para separar entre vegetación y suelo. A continuación, se clasifica cada píxel según el umbral y se aplica un filtro de mediana de 5x5 píxeles para mejorar la presentación del resultado. Finalmente, se presentan y evalúan los resultados obtenidos.

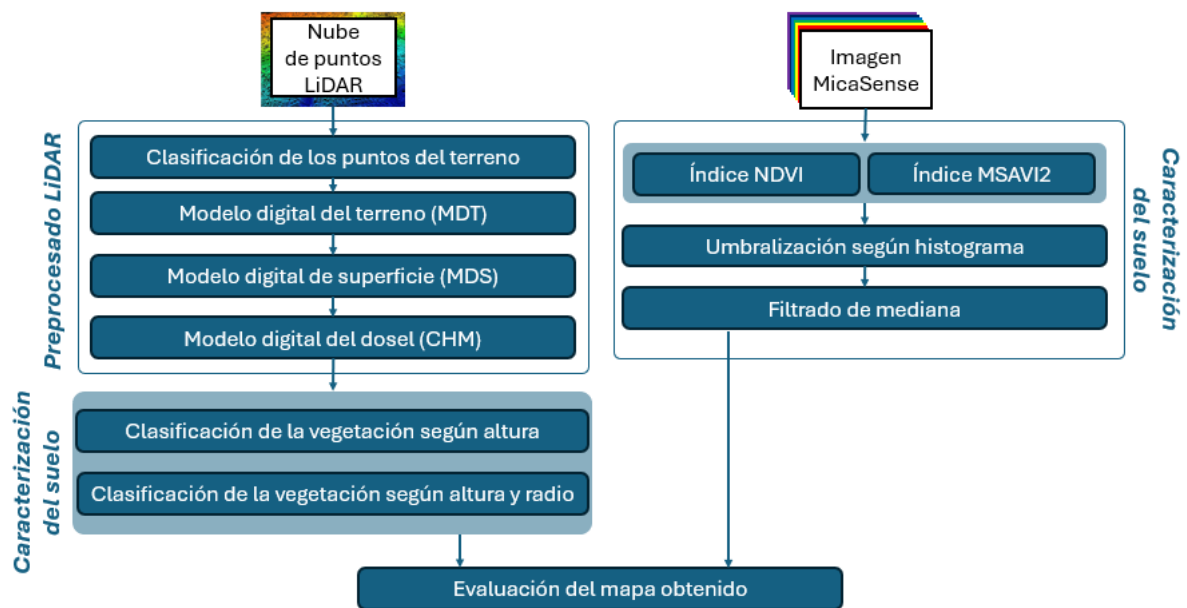


Figura 4.4. Esquema general de la metodología para la caracterización del suelo.

Para el desarrollo del preprocesado LiDAR y la caracterización del suelo en ambos casos, excepto la clasificación LiDAR por altura y radio, se hace uso de la herramienta de código abierto *QGIS* [49], con el complemento de la librería *LAStools* [50]. Por otro lado, la aplicación *ENVI LiDAR* dentro del entorno *ENVI* permite la clasificación de nubes de puntos LiDAR según altura y radio.

4.1. CARACTERIZACIÓN DEL SUELO CON NUBE DE PUNTOS LiDAR

La tecnología LiDAR ha marcado un paradigma en la teledetección. Al ser un sensor activo, entre sus aplicaciones destaca la generación de modelos digitales, así como su utilidad en cartografía o el control y gestión forestal. En este último caso, la capacidad de penetrar en espacios reducidos, como las hojas de un árbol, permite captar más detalles y realizar mediciones directas del tronco o el suelo bajo la vegetación. De esta manera, los datos LiDAR han generado resultados precisos en diversos estudios forestales con fines como la segmentación de árboles [51] o la clasificación de especies según altura o intensidad de la nube de puntos [52].

En el presente TFM, se propone hacer uso de una nube de datos LiDAR para clasificar la población de vinagreras en el Parque Nacional de Timanfaya, y comparar las técnicas de clasificación por altura y por altura y radio. Para ello, se sigue la metodología descrita en la Figura 4.5.



Figura 4.5. Esquema general de la metodología utilizada para la caracterización del suelo mediante nube de puntos LiDAR.

4.1.1. PREPROCESADO LiDAR

El preprocesado LiDAR tiene como objetivo generar modelos con los que normalizar la nube de puntos y obtener la altura real de los objetos. Estos modelos son el MDT, MDS y CHM. Sin embargo, hay un paso previo a la obtención de los modelos que consiste en la clasificación de los puntos de tierra, ya que algunos modelos se generan a partir de esta clasificación. Este proceso se puede realizar de manera automática mediante diferentes algoritmos [53]. En este caso, se realiza el filtrado mediante una red de triangulación irregular (*Triangulated Irregular Network, TIN*).

La Figura 4.6 muestra un ejemplo de los modelos MDT, MDS y CHM. Inicialmente, partiendo de los puntos del suelo clasificados, se puede generar el MDT, que representa la superficie terrestre sin incluir vegetación, edificios u otros objetos. Para ello, se eliminan los puntos clasificados como no suelo previamente. A partir de los puntos de tierra, se puede obtener una superficie continua del terreno mediante diferentes métodos de interpolación [54]. En este caso, se utiliza el método de interpolación TIN, en la que se crean superficies delimitadas por los triángulos que forman tres puntos cercanos entre sí y sus alturas. La obtención del MDT es necesaria para normalizar la nube de puntos y estimar la altura real de los objetos.

Posteriormente, el MDS se genera a partir de la nube de puntos original y permite obtener un modelo que representa la superficie del terreno incluyendo todos los elementos situados sobre este, como vegetación o edificios. Para ello, se genera una superficie continua mediante interpolación de todos los puntos disponibles.

Finalmente, el CHM es el modelo que representa las elevaciones del dosel arbóreo. Este modelo se genera mediante la diferencia entre el MDS y el MDT, de la que se obtiene un modelo normalizado con las superficies de las copas de los árboles sobre un terreno plano.




Figura 4.6. Representación ejemplo de los modelos MDT, MDS y CHM.

4.1.2. RESULTADOS

A continuación, se presentan los resultados del preprocesado y clasificación de la nube de puntos LiDAR para obtener la caracterización del suelo del área de estudio. La Figura 4.7 muestra la nube de puntos con la tierra clasificada, como primer paso para generar los modelos del terreno.



Figura 4.7. Nube de puntos LiDAR clasificada: tierra (naranja) y no tierra (blanco).

A partir de la nube de puntos LiDAR clasificada, se generan los modelos MDT y MDS, que se muestran en la Figura 4.8. Se puede apreciar que el MDT, al representar el terreno, se presenta como un modelo menos abrupto con zonas más planas. Por otra parte, el MDS generado presenta las partes superiores de cada uno de los diversos arbustos de vinagrera situados en el área de estudio.




Figura 4.8. Modelos digitales del área de estudio: (a) MDT y (b) MDS.

Para comprobar que el MDT se ha realizado correctamente, se puede realizar una comparación con los datos que proporciona el Instituto Geográfico Nacional (IGN) español a través del Plan Nacional de Ortofotografía Aérea (PNOA). El PNOA dispone, entre otros, de nubes de puntos LiDAR y MDT de libre acceso de todo el territorio nacional. Del área de estudio se encuentra disponible el MDT con una resolución espacial de 2 m del año 2015. A partir del perfil de elevación del MDT generado y la referencia, se puede realizar una comparación para evaluar los resultados. La Figura 4.9 muestra la comparación entre el MDT de referencia (rojo) y el MDT generado (azul). Se puede apreciar la diferencia en resolución, ya que el MDT generado presenta variaciones con mayor detalle y de manera continua. Al realizar la comparación, el resultado se asemeja notablemente a la referencia, por lo que se puede validar la calidad del MDT obtenido sin ser completamente exacto. Se puede observar una diferencia de *offset* de 5 m aproximadamente entre ambos modelos. Esta diferencia se puede deber a distintas referencias del nivel del mar de cada uno de los sensores. Sin embargo, esta diferencia altura reflejada en el eje Z de los datos LiDAR no presenta inconvenientes para el desarrollo del TFM, ya que se normalizan los datos para obtener las alturas reales de los objetos.

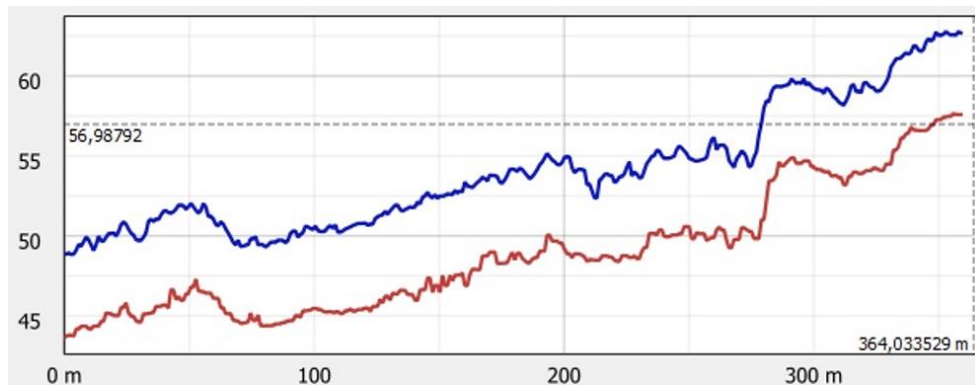


Figura 4.9. Perfil de elevación del MDT con resolución 2 metros del PNOA (rojo) y el MDT con resolución aproximada de 10 cm generada por el Zenmuse L1 (azul).

A partir de los modelos expuestos anteriormente, se ha generado el CHM, representado en la Figura 4.10. Se destaca que el terreno se presenta como una superficie plana al contrario que en los modelos anteriores. Además, la altura de los elementos de la nube de puntos se dispone de manera normalizada, lo que permite identificar las alturas reales de los elementos de la nube de puntos. Esta información es necesaria para poder realizar la clasificación de la vegetación.




Figura 4.10. CHM del área de estudio.

A partir del CHM, se realiza la caracterización del suelo clasificando los puntos LiDAR según su altura. Para ello, se ha comprobado la altura de diversos arbustos de vinagrera según los puntos LiDAR. Además, se han utilizado diferentes alturas para generar mapas, llegando a la conclusión de que se presentan mejores resultados cualitativos ajustando el umbral a la altura mínima de los arbustos, correspondiente a los 0,2m. Utilizando esta altura como umbral, se ha clasificado la nube de puntos en vegetación y no vegetación. La Figura 4.11 muestra el mapa de caracterización del suelo obtenido.




Figura 4.11. Caracterización del suelo del área de estudio con altura umbral de 20 cm: vegetación (verde) y tierra (marrón).

El resultado obtenido no representa correctamente la caracterización del suelo del área de estudio. Presenta evidentes errores en muchas zonas, destacando parte del camino de tierra y el malpaís situado a la derecha de la imagen. Ambas zonas no poseen presencia de vegetación. En la Figura 4.12 se presenta una pequeña área con varios arbustos en la que no se ha conseguido clasificar todos correctamente, siendo la vinagrera resaltada la única identificada completamente como vegetación.




Figura 4.12. Estudio de la clasificación de vegetación resaltando el arbusto mejor identificado: (a) nube de puntos LiDAR original, (b) caracterización del suelo por altura.

Con el propósito de mejorar este resultado, se realizó una clasificación que tuviera en cuenta otros parámetros. En este caso, se sumó el radio de los arbustos a la altura. Al igual que con la altura, se realizó una serie de pruebas para comprobar el radio que presentara mejores valores cualitativos, que se correspondió con un radio de 0,25m. Manteniendo la altura mínima de 0,2 m y con un radio mínimo de 0,25m, se generó un mapa clasificado con la caracterización del suelo, que se muestra en la Figura 4.13. La clasificación con ambos parámetros genera un mapa caracterizado

y dividido en más clases. En este caso, se obtiene la clasificación de tierra (marrón), vegetación según altura (verde claro), vegetación según altura y radio (verde oscuro) y puntos no clasificados (blanco).




Figura 4.13. Caracterización del suelo del área de estudio con altura umbral de 20 cm y radio mínimo de 25 cm: vegetación por altura (verde claro), por altura y radio (verde oscuro), tierra (marrón) y no clasificados (blanco).

La caracterización del mapa obtenida mediante este método presenta una mejor clasificación de la vegetación respecto a la clasificación solo por altura. Sin embargo, no mejora notablemente el resultado anterior para obtener una caracterización del suelo coherente. Por ello, se presenta una gran complejidad de obtener una caracterización del suelo óptima de la zona de estudio con los datos LiDAR.

Tras evaluar los resultados obtenidos, se ha planteado un estudio de la nube de puntos capturada para comprobar la viabilidad de realizar la caracterización del suelo del área de estudio según la altura de los arbustos.

La Figura 4.14 muestra una imagen del área de estudio. En esta imagen, se puede apreciar la sequía de la tierra en esta zona, junto a la gran densidad de arbustos. Además, la altura de la vegetación es muy baja, como ya se comprobó con el valor umbral utilizado en la clasificación y los arbustos a identificar presentan una tupidez notoria, debida principalmente a las numerosas ramas que los forman. Esta tupidez provoca que, en la captura de puntos, no se pueda atravesar las ramas y conseguir puntos internos del arbusto o puntos del suelo. Esta información es muy relevante para poder clasificar correctamente los puntos de suelo de los datos LiDAR y diferenciar entre suelo y arbustos según la altura.



Figura 4.14. Imagen del área de estudio dentro del Parque Nacional de Timanfaya, Google Maps®.

A partir de esta información, se ha evaluado el perfil de elevación de los datos LiDAR para comprobar la complejidad de diferenciar suelo de vegetación. Esta evaluación se ha realizado comprobando el comportamiento de la nube de puntos en distintas situaciones. La Figura 4.15 muestra un caso de estudio en el que se encuentra el perfil de elevación de un arbusto aislado. Además, se toma la medida del perfil de elevación con el suelo clasificado y del perfil de elevación con los puntos normalizados y clasificados a 0,2 m. La primera apreciación en ambos perfiles es el ruido en la toma de puntos, que se presenta tanto en las zonas de suelo como en el arbusto, y que no permite obtener una superficie continua. Se debe tener en cuenta que la resolución vertical máxima del sensor Zenmuse L1 es de 5 cm a 50 m de altura, por lo que, a mayor altitud de vuelo, menor resolución vertical de los datos. En este caso, el dron se voló a una altura superior a 50 m, haciendo que la resolución vertical no permita identificar correctamente los arbustos. Esto se debe a que la altura de las vinagreras no es suficiente respecto de la resolución vertical para que el ruido en la captura de datos sea despreciable. Además, aun disponiendo de una resolución de 5 cm, el ruido presente en la captura de datos no favorece la clasificación por altura. Otro aspecto importante es la clasificación como tierra de los puntos presentes entre las cotas de 2,5 y 3 m del perfil, que realmente forman parte del arbusto. Esto se debe a la tupidez descrita anteriormente, que no permite al láser LiDAR atravesar la vinagrera y tomar retornos del suelo. Esta condición provoca que el algoritmo de clasificación no consiga diferenciar los puntos de tierra correctamente. De esta manera, en la normalización de los datos se puede comprobar cómo se establecen los puntos centrales del arbusto como puntos sin altura, disponiendo así de una clasificación errónea en la caracterización del suelo.





Figura 4.15. Perfil de elevación de nube de puntos con suelo clasificado y con vegetación clasificada de un arbusto aislado.

Por otro lado, la Figura 4.16 muestra otro caso de estudio, que se ubica en una agrupación de dos arbustos con una separación pequeña entre ellos. En la clasificación del suelo, se puede observar nuevamente la dispersión presente en la nube de puntos debido al ruido, y la clasificación de puntos de suelo erróneos debido a la densidad de ramas en los arbustos. Esto provoca que, en la clasificación de vegetación, el arbusto izquierdo se clasifique mínimamente y que el arbusto derecho sea considerado prácticamente como suelo.

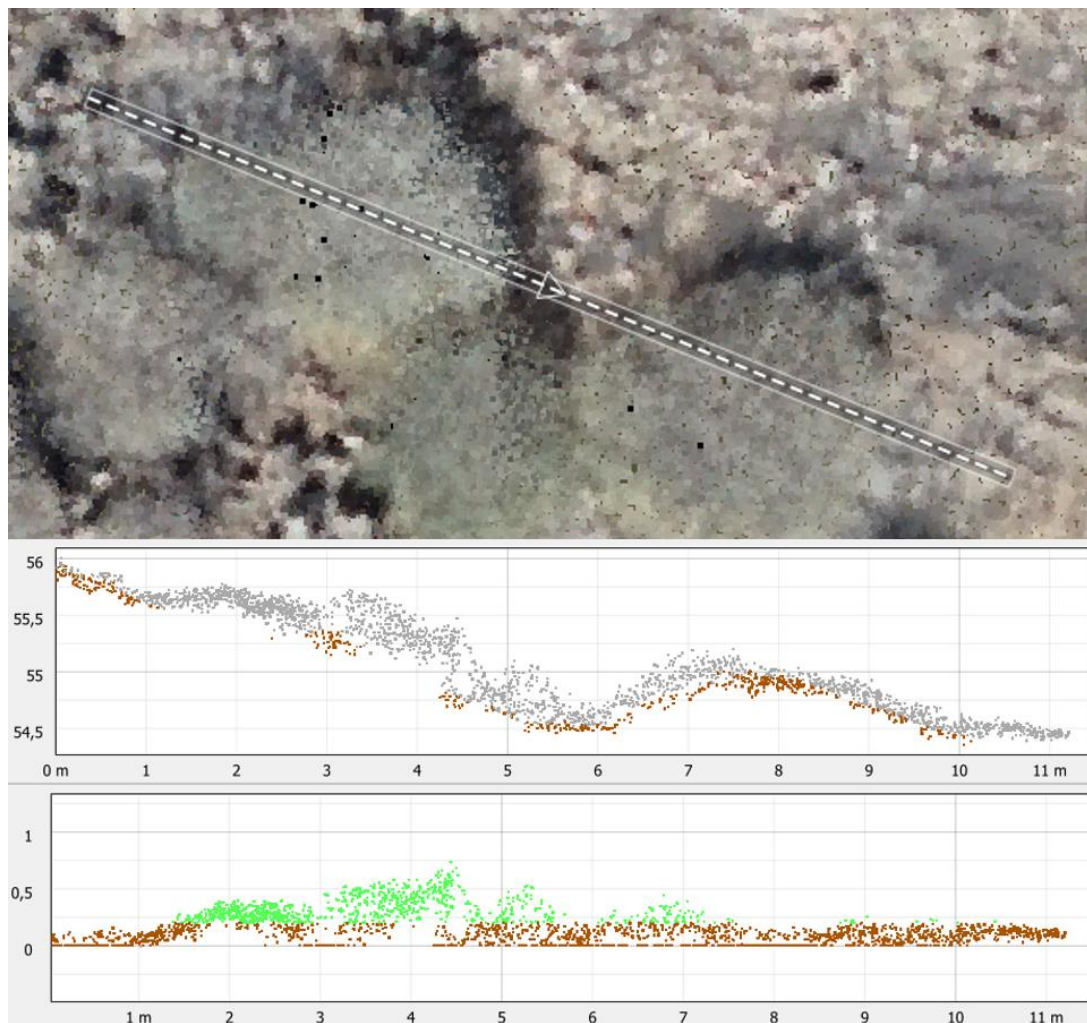


Figura 4.16. Perfil de elevación de nube de puntos con suelo clasificado y con vegetación clasificada de una agrupación de arbustos.

La información LiDAR posee gran valor para identificar, clasificar y segmentar vegetación, siendo una fuente de datos útil en muchas aplicaciones forestales. Sin embargo, en este caso, debido a la poca altura y tupidez de la vegetación, además del ruido del sensor, no se obtienen resultados adecuados. La propia captura de los datos genera nubes de puntos con errores, ya que no se puede obtener puntos del suelo bajo los arbustos. Además, la altura de la vegetación es un problema adicional. En la clasificación se ha fijado una altura umbral de 0,2 m debido a la observación de la altura de los arbustos según la nube de puntos y modificar este valor no mejora el resultado. Al disminuirlo, se puede mejorar la clasificación de los arbustos más pequeños o de los puntos erróneamente asignados como suelo. Sin embargo, el ruido presente en la nube introduciría muchos puntos de tierra, rocas u otros elementos no vegetativos en la clasificación. Por otro lado, aumentar la altura umbral limitaría aún más la identificación de arbustos de menor tamaño. Por ello, se plantea utilizar otra fuente de información, como imágenes multiespectrales, para realizar la caracterización del suelo del área de estudio en el Parque Nacional de Timanfaya.

4.2. CARACTERIZACIÓN DEL SUELO CON IMAGEN MULTIESPECTRAL DE MUY ALTA RESOLUCIÓN

Otra forma de caracterizar la vegetación es mediante el uso de imágenes multiespectrales de muy alta resolución. Las imágenes multiespectrales permiten la identificación de vegetación, así como estudiar su salud y cobertura, mediante el uso de índices de vegetación.

De forma general, los índices espectrales consisten en combinaciones de bandas que permiten diferenciar una propiedad de los objetos de estudio. En concreto, los índices de vegetación utilizan normalmente las bandas rojo e infrarrojo cercano (NIR) para destacar la presencia de vegetación [55]. Esto se debe a que la vegetación absorbe en gran medida la luz visible mediante la clorofila, teniendo un pico de absorción en el rojo, y refleja enormemente la banda NIR. La reflectividad espectral de la vegetación, junto a la de otras superficies, se muestra en la Figura 4.17, donde se puede apreciar la alta absorción de la clorofila en la banda roja, 650 nm aproximadamente, y la baja absorción en la banda NIR.




Figura 4.17. Firma espectral del suelo, vegetación y agua [56].

En este TFM, se plantea el uso de los índices vegetativos NDVI (*Normalized Difference Vegetation Index*) y MSAVI2 (*Modified Soil Adjusted Vegetation Index*) sobre la imagen multiespectral MicaSense para caracterizar el suelo del área de estudio dentro del Parque Nacional de Timanfaya, siguiendo la metodología que se muestra en la Figura 4.18.




Figura 4.18. Esquema general de la metodología utilizada para la caracterización del suelo mediante imagen multispectral.

En este caso, la imagen multispectral MicaSense no requiere de preprocesado. Al igual que en el caso de la imagen Pika L utilizada en la batimetría, se debe considerar que no es necesario aplicar correcciones atmosféricas en imágenes dron donde el vuelo se realice a baja altitud, ya que el efecto de la atmósfera se desprecia o no afecta a la imagen capturada.

4.2.1. ÍNDICE DE VEGETACIÓN DE DIFERENCIA NORMALIZADA (NDVI)

El Índice de Vegetación de Diferencia Normalizada (NDVI) [55] es el índice más utilizado para imágenes multispectrales. Permite medir la salud y densidad de vegetación en imágenes multispectrales e hiperespectrales. Este índice compara la diferencia entre la banda NIR y la banda roja, como muestra la ecuación (4.1). Cuando la vegetación se deteriora, absorbe más energía en la banda NIR. De esta manera, la variación de la banda NIR respecto a la banda roja proporciona información sobre la presencia de vegetación.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (4.1)$$

El rango de valores NDVI va desde -1 a 1, donde los valores negativos y cercanos a 0 indican ausencia de vegetación y, a medida que aumenta el valor, se representan baja, media y alta vegetación.

4.2.2. ÍNDICE DE VEGETACIÓN AJUSTADO AL SUELO MODIFICADO (MSAVI2)

El Índice de Vegetación Ajustado al Suelo Modificado (MSAVI2) [57] se utiliza como variante para ampliar los límites de aplicación del índice NDVI. NDVI presenta ciertas limitaciones para detectar vegetación en áreas de suelo desnudo, escasa vegetación o falta de clorofila en las plantas, como en este caso de estudio. Por ello, el MSAVI2 permite minimizar la influencia del suelo desnudo y

aumentar el rango dinámico que indica la presencia de vegetación. La ecuación (4.2) muestra el cálculo del índice MSAVI2.

$$MSAVI2 = \frac{2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8(NIR - RED)}}{2} \quad (4.2)$$

Las aplicaciones de uso van desde el análisis del crecimiento de las plantas a la investigación de la desertificación o vigilancia de la sequía y erosión del suelo.

4.2.3. UMBRALIZACIÓN

La umbralización es una técnica de segmentación que permite separar píxeles de una imagen en dos clases a partir de un valor umbral de intensidad, diferenciando así los objetos del fondo [58].

Existen diferentes maneras de umbralizar, siendo el método más común y sencillo el umbral global. Este método se basa en aplicar a toda la imagen el mismo valor umbral, clasificando de la siguiente manera:

$$p(x, y) = \begin{cases} Clase_0, & I(x, y) < T, \\ Clase_1, & I(x, y) \geq T \end{cases} \quad (4.3)$$

donde $p(x, y)$ es un píxel en las coordenadas X e Y de la imagen, $I(x, y)$ representa la intensidad en ese píxel y T corresponde al valor umbral global. EL valor umbral se puede obtener mediante el histograma. El histograma de una imagen representa gráficamente el número de píxeles con la misma intensidad, para cada valor de intensidad. La Figura 4.19 representa el proceso de elección del valor umbral en un histograma bimodal. A partir del histograma, se identifica el elemento que se pretende separar del resto según su valor de intensidad, es decir, se diferencian las clases. Posteriormente, se establece el umbral en el valor que mejor separe ambas clases.




Figura 4.19. Proceso de elección de valor umbral global mediante histograma bimodal.

4.2.4. RESULTADOS

En este apartado se presentan los resultados obtenidos de la caracterización del suelo del área de estudio utilizando la imagen multiespectral MicaSense. En primer lugar, se muestran los resultados con el índice NDVI y los mapas según el índice MSAVI2. Finalmente, se comparan la calidad de los índices y se estudian los resultados respecto a la clasificación LiDAR.

- NDVI

La Figura 4.20 muestra el índice NDVI de la imagen multiespectral MicaSense. Los valores se han coloreado en una escala de verdes para mejorar la representación, donde mayores valores del índice se reflejan con verdes más intensos.




Figura 4.20. Imagen MicaSense con valores NDVI en escala de verdes.

Para clasificar entre vegetación y suelo, es necesario definir un valor umbral que permita separar ambas clases. Para ello, se analiza el histograma de la imagen NDVI, que se presenta en la Figura 4.21. El valor umbral óptimo se encontraría entre agrupaciones de píxeles con valores NDVI muy diferenciados. En este caso, se presenta un histograma donde no existe una diferencia notoria entre vegetación y suelo. Por ello, se debe identificar los valores donde existe mayor concentración de cada clase. Por un lado, el suelo presenta una distribución que se concentra con claridad entre los valores 0 y 0,1. Por otro lado, la vegetación no presenta una distribución que destaque en el histograma. Sin embargo, se puede observar un ligero valle en el valor 0,12, donde se aprecia la

unión de las dos agrupaciones. Por ello, se ha estimado un umbral de 0,12 como valor óptimo para separar ambas clases.




Figura 4.21. Histograma de los valores del índice NDVI.

Con este valor de umbral, se han clasificado los píxeles con valores superiores a 0,12 como vegetación y los píxeles inferiores como no vegetación. Tras la clasificación, se obtiene el producto que se muestra en la Figura 4.22, donde en blanco se representa la vegetación.




Figura 4.22. Clasificación con umbral NDVI de 0,12 entre vegetación (blanco) y suelo (negro).

De esta forma, se obtiene la caracterización del suelo del área de estudio. Sin embargo, se presentan diversos píxeles sueltos que introducen ruido al mapa. Para solucionarlo, se ha aplicado un filtro de mediana de 5x5 píxeles para eliminar el ruido y, a su vez, definir los contornos de la vegetación con mayor claridad. La Figura 4.23 muestra la diferencia en la caracterización del suelo NDVI antes y después de aplicar el filtrado.




Figura 4.23. Comparación de la clasificación NDVI: (a) sin filtrado, (b) con filtrado de mediana 5x5.

Finalmente, en la Figura 4.24 se muestra la superposición de la caracterización del suelo a la imagen MicaSense original, donde el mapa NDVI se representa en verde. Cualitativamente, se aprecia un resultado óptimo. Al ser utilizado un índice centrado en la vegetación, el camino de tierra y la zona del malpaís presentes a la derecha de la imagen se filtran completamente y la identificación de la vegetación se realiza de manera correcta.




Figura 4.24. Caracterización del suelo del área de estudio según NDVI (verde) sobre imagen MicaSense original.

- **MSAVI2**

Para el índice MSAVI2 se ha seguido el mismo procedimiento. La Figura 4.25 muestra el producto obtenido de aplicar el índice MSAVI2 a la imagen multispectral MicaSense. Se ha representado en escalada de verdes para mejorar la representación, donde mayores valores del índice se reflejan con verdes más intensos.




Figura 4.25. Imagen MicaSense con valores MSAVI2 en escala de verdes.

Seguidamente, se analiza el histograma de la imagen MSAVI2, que se presenta en la Figura 4.26. Al igual que el caso del índice NDVI, en el histograma no se aprecia una diferencia clara entre vegetación y suelo. No obstante, en este caso la vegetación presenta una distribución más notable que en el índice NDVI. Esto permite definir el umbral con mayor precisión en el valle que indica la unión entre los valores de suelo y vegetación. En este caso, se ha estimado un umbral de 0,22 como valor umbral.

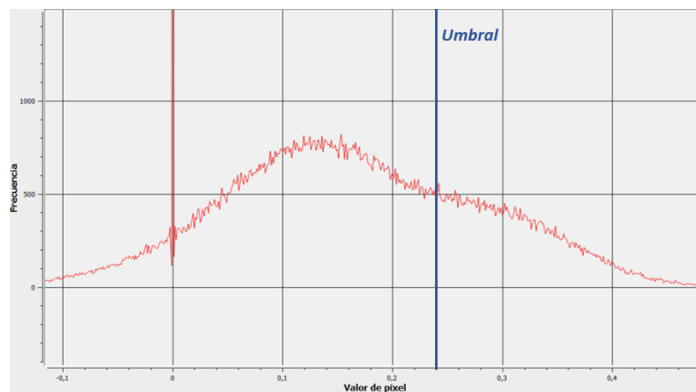


Figura 4.26. Histograma de los valores MSAVI2.

Tras definir el umbral, se clasifican los píxeles, obteniendo el mapa que se muestra en la Figura 4.27, con la vegetación representada de color blanco.




Figura 4.27. Clasificación con umbral MSAVI2 de 0,22 entre vegetación (blanco) y suelo (negro).

Sobre la clasificación realizada se aplica el filtrado de mediana de 5x5 píxeles para eliminar posible ruido y delimitar los bordes de la clasificación. Finalmente, se superpone el mapa de vegetación MSAVI, representado en naranja, a la imagen original MicaSense, como muestra la Figura 4.28. Este resultado permite identificar correctamente las vinagreras de la imagen con precisión y filtrar de manera óptima las zonas con ausencia de vegetación.




Figura 4.28. Caracterización del suelo del área de estudio según MSAVI2 (naranja) sobre imagen MicaSense original.

▪ COMPARACIÓN DE RESULTADOS

Finalmente, se comparan los mapas de caracterización del suelo obtenidos con la imagen multispectral y los datos LiDAR. La Figura 4.29 muestra una zona con vegetación, malpaís y carretera. Se puede apreciar como los índices NDVI y MSAVI2 presentan un resultado muy similar,

identificando correctamente la vegetación y sin introducir errores de clasificación con el suelo. Sin embargo, la clasificación LiDAR presenta errores graves en la clasificación, al identificar suelo como la vegetación.




Figura 4.29. Comparación de la caracterización del suelo: (a) imagen MicaSense original con las zonas de posible vegetación resaltadas en verde, (b) resultado con índice NDVI, (c) resultado con el índice MSAVI2, (d) resultado LiDAR según altura.

Al comparar cualitativamente los mapas generados por los índices NDVI y MSAVI2, se puede observar que ambos mapas presentan resultados aceptables para identificar la vegetación y que son muy similares entre sí. Sin embargo, el índice MSAVI2 permite umbralizar ligeramente mejor la vegetación y el suelo, aportando mayor fiabilidad al resultado.

4.3. RESUMEN

En este capítulo se han descrito y evaluado las diferentes técnicas para la caracterización del suelo del área de estudio. Inicialmente, se ha expuesto el área de estudio, que corresponde a una zona con alta concentración de vinagreras en el Parque Nacional de Timanfaya, así como los productos LiDAR y multiespectral utilizados. La monitorización de las vinagreras en Timanfaya es de gran relevancia por su capacidad invasiva en el ecosistema.

En el caso de la nube de puntos LiDAR, se ha explicado la metodología aplicada, partiendo de la generación de diferentes modelos del terreno como parte del preprocesado. Además, se han mostrado los resultados obtenidos de cada uno de los modelos del terreno y de la clasificación de

la vegetación según altura, y altura junto a radio. Finalmente, tras realizar un estudio de la calidad de la nube de puntos capturada y de la zona, la tupidez propia de las vinagreras, y la baja altura, presentan un reto muy complejo para realizar la clasificación según los parámetros mencionados.

Por otro lado, se ha utilizado una imagen multiespectral obtenida por el sensor óptico pasivo MicaSense en el mismo vuelo dron. A partir de la imagen multiespectral, se han podido aplicar y umbralizar los índices de vegetación NDVI y MSAVI2 con el fin de caracterizar el suelo mediante la identificación y clasificación de la vegetación. De manera cualitativa, estos índices han permitido generar mapas aceptables de la vegetación y no existe diferencia notoria entre ellos.

Capítulo 5: CONCLUSIONES

En este Trabajo Fin de Máster, se ha realizado el estudio de litorales y parques nacionales dentro del archipiélago canario mediante el procesado de imágenes multiespectrales, hiperespectrales y datos LiDAR para la obtención de mapas de batimetría, hábitats bentónicos y de caracterización de suelo. Para ello, se han estudiado los sensores que capturaron las imágenes utilizadas en este TFM, formados por los sensores multiespectrales de los satélites Sentinel-2 y WorldView-2, y los sensores dron multiespectral MicaSense Dual, hiperespectral Pika L y LiDAR Zenmuse L1.

Además, se han estudiado las técnicas de preprocesado para imágenes de teledetección en cada ámbito de estudio. Estas técnicas están formadas por la georreferenciación, la calibración radiométrica, la corrección atmosférica, la máscara de agua y la corrección del brillo solar. Igualmente, se ha realizado el preprocesado LiDAR, que ha consistido en la clasificación de puntos suelo y la generación del modelo digital del terreno, el modelo digital de la superficie y el modelo de altura del dosel.

Posteriormente, se han generado los mapas de batimetría, hábitats bentónicos y caracterización del suelo de las áreas de estudio mediante diversos métodos, como modelos *Machine Learning*, modelos físicos, clasificación de puntos LiDAR e índices de vegetación. Finalmente, se ha realizado el análisis de los resultados obtenidos en cada ámbito de estudio, con el fin de destacar los modelos y tecnologías óptimas para cada zona de estudio. Las áreas de estudio escogidas corresponden a ecosistemas protegidos del archipiélago canario, que presentan una elevada vulnerabilidad al impacto de las actividades humanas y son de gran interés biológico y económico. Las zonas de estudio seleccionadas han sido El Río, entre La Graciosa y Lanzarote, para

lo monitorización marina y el Parque Nacional de Timanfaya en Lanzarote, para la monitorización terrestre.

A continuación, se enumeran las principales conclusiones de este Trabajo Fin de Máster:

- Respecto a la generación de mapas de batimetría, estos permiten realizar el estudio de la evolución de la topografía marina. Este estudio resulta de gran utilidad en zonas, como El Río, que se ven fuertemente influenciadas por las continuas corrientes marinas. Además, permite observar las zonas donde se acumulan mayores sedimentos, como arena o rocas, donde estos cambios pueden afectar a las especies bentónicas del área de estudio. Para generar los mapas de batimetría se ha realizado un estudio multialgoritmo. En la imagen WorldView-2, el modelo *Machine Learning SVM* genera mejores resultados cuantitativos que el modelo físico SBM. Sin embargo, el modelo SBM genera un mapa de mayor coherencia y calidad, debido a que sus errores se deben a sobreajustes en zonas de poca profundidad. Los resultados obtenidos con la imagen multiespectral WorldView-2 han destacado frente a los obtenidos con la imagen hiperespectral Pika L por su relación calidad-coste y por la cobertura que ofrece del área de estudio. Mientras, la imagen Pika L destaca para estudios más exhaustivos de pequeñas zonas.
- Respecto a la generación de mapa de hábitats bentónicos, se ha utilizado la técnica de *Machine Learning* denominada *Support Vector Machine*. Además, se ha coordinado una campaña de campo para tomar medidas *in-situ* del área de estudio, con el fin de generar los datos para entrenar y evaluar el modelo. A partir de esta información, se ha generado el mapa de hábitats bentónicos con la imagen satelital WorldView-2. Al analizar los resultados, se ha comprobado la complejidad presente en la clasificación del fondo marino de El Río, ya que no se obtenido un mapa clasificado correctamente. Por ello, han sido necesarios procesos adicionales para poder generar un mapa coherente con la imagen WorldView-2. No obstante, con la imagen Pika L se ha podido generar un mapa de mayor calidad sin ajustes adicionales, debido a su mayor resolución espectral y espacial. Se puede concluir que el proceso de clasificación del fondo marino depende en gran medida de la separabilidad espectral de las especies y su tamaño respecto a la resolución del sensor. Adicionalmente, se ha realizado un análisis de la evolución temporal de la población de sebadal (*Cymodocea nodosa*) de El Río utilizando estudios previos, donde se ha podido observar la disminución del sebadal durante los últimos años. Este trabajo permite destacar la necesidad de realizar estudios continuos en zonas protegidas para evitar y contener la desaparición de especies vegetales marinas, como el sebadal.

- Respecto a la caracterización del suelo, se ha generado estos mapas mediante datos LiDAR. Para ello, se ha realizado el preprocesado LiDAR, que consiste en la clasificación de los puntos de suelo y la generación de diferentes modelos del terreno para obtener las alturas normalizadas de los elementos que forman la nube de puntos. Sin embargo, la vegetación del Parque Nacional de Timanfaya presenta ciertas condiciones, como la altura de las vinagreras y su tupidez, que han provocado que la clasificación de las nubes de puntos genere mapas con gran cantidad de errores. Por ello, se ha requerido de otra fuente de información para generar los mapas. El uso de los índices de vegetación NDVI y MSAVI2 en la imagen multiespectral dron ha permitido caracterizar el suelo del área de estudio mediante umbralización. Cualitativamente, los resultados obtenidos con este método presentan mejoría en la identificación las vinagreras respecto a los mapas LiDAR. Con estos resultados, se puede concluir que los mapas de caracterización del suelo son útiles para estudiar la población invasora de las vinagreras en el Parque Nacional de Timanfaya y ayudar al control y vigilancia de la especie tanto en las zonas de aislamiento como en el resto del parque. Cabe destacar que no se aconseja el uso de datos LiDAR para caracterizar el suelo en superficies con vegetación de muy baja altura, como es el caso de este TFM. Además, la imagen multiespectral se presenta como el producto que mejor se adapta a las condiciones del área de estudio.

Durante el desarrollo de este Trabajo Fin de Máster se ha comprobado la utilidad de las imágenes de teledetección para realizar estudios y monitorizar litorales y superficies terrestres. Adicionalmente, este Trabajo Fin de Máster se considera una base para posibles líneas futuras en este campo de trabajo. Las principales líneas futuras son:

- Profundizar en el uso de técnicas de *Deep Learning* para la generación de mapas. En este TFM se ha realizado la clasificación y segmentación por píxeles, teniendo en cuenta la información espectral que disponen. Sin embargo, no se utiliza la información espacial de la imagen, como podría ser el contorno de los objetos de estudio. Para aprovechar esta información se podría hacer uso de modelos *Deep Learning* de segmentación como las Redes Neuronales Convolucionales. Específicamente, se plantea el uso de *Deep Learning* en la generación de mapas de hábitats bentónicos en el Río, debido a las dificultades encontradas en la clasificación de píxel utilizando únicamente la información espectral.
- Realizar un estudio multitemporal de la batimetría de El Río, mediante imágenes WorldView-2, para monitorizar posibles cambios en la topografía marina y predecir

posibles acumulaciones de sedimentos que pongan en peligro las comunidades bentónicas de la zona.

- Obtener medidas de campo de las vinagreras en el área de estudio del Parque Nacional de Timanfaya para mejorar la segmentación de los arbustos mediante datos LiDAR, cuantificar los resultados obtenidos con los índices NDVI y MSAVI2 y realizar estudios del estado de la vegetación con modelos de aprendizaje supervisado.
- Estudiar el uso de imágenes WorldView-2 para generar mapas de caracterización del suelo y monitorizar el Parque Nacional de Timanfaya, debida a su menor coste y mayor cobertura respecto a imágenes dron.

BIBLIOGRAFÍA

- [1] S. Khorram, F. H. Koch, Van der Wiele C. F., y S. A. & Nelson, *Remote sensing*. Springer Science & Business Media, 2012.
- [2] «Home | IHO». Accedido: 8 de febrero de 2024. [En línea]. Disponible en: <https://iho.int/>
- [3] Marta. Música de la Guerra, Fundación Interuniversitaria Fernando González Bernáldez, y EUROPARC-España., *Anuario 2020 del estado de las áreas protegidas en España*. Fundación Fernando González Bernáldez, 2021.
- [4] S. Jawak, S. Vadlamani, y A. Luis, «A Synoptic Review on Deriving Bathymetry Information Using Remote Sensing Technologies: Models, Methods and Comparisons», *Advances in Remote Sensing*, vol. 4, pp. 147-162, feb. 2015, doi: 10.4236/ars.2015.42013.
- [5] D. Lyzenga, «Passive Remote-Sensing Techniques for Mapping Water Depth and Bottom Features», *Appl Opt*, vol. 17, pp. 379-383, ene. 1978, doi: 10.1364/AO.17.000379.
- [6] R. P. Stumpf, K. Holderied, y M. Sinclair, «Determination of water depth with high-resolution satellite imagery over variable bottom types», *Limnol Oceanogr*, vol. 48, n.º 1 II, pp. 547-556, 2003, doi: 10.4319/LO.2003.48.1_PART_2.0547.
- [7] A. Misra, Z. Vojinovic, B. Ramakrishnan, A. Luijendijk, y R. Ranasinghe, «Shallow water bathymetry mapping using Support Vector Machine (SVM) technique and multispectral imagery», *Int J Remote Sens*, vol. 39, n.º 13, pp. 4431-4450, jul. 2018, doi: 10.1080/01431161.2017.1421796.
- [8] J. Kibele y N. T. Shears, «Nonparametric Empirical Depth Regression for Bathymetric Mapping in Coastal Waters», *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 9, n.º 11, pp. 5130-5138, nov. 2016, doi: 10.1109/JSTARS.2016.2598152.
- [9] F. Eugenio, J. Marcello, A. Mederos-Barrera, y F. Marques, «High-Resolution Satellite Bathymetry Mapping: Regression and Machine Learning-Based Approaches», *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, 2022, doi: 10.1109/TGRS.2021.3135462.
- [10] F. Eugenio, J. Marcello, y J. Martin, «High-Resolution Maps of Bathymetry and Benthic Habitats in Shallow-Water Environments Using Multispectral Remote Sensing Imagery»,

- IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, n.º 7, pp. 3539-3549, jul. 2015, doi: 10.1109/TGRS.2014.2377300.
- [11] P. Wicaksono, P. Aryaguna, y W. Lazuardi, «Benthic Habitat Mapping Model and Cross Validation Using Machine-Learning Classification Algorithms», *Remote Sens (Basel)*, vol. 11, p. 1279, feb. 2019, doi: 10.3390/rs11111279.
- [12] A. Mederos-Barrera, J. Marcello, F. Eugenio, y E. Hernández, «Seagrass mapping using high resolution multispectral satellite imagery: A comparison of water column correction models», *International Journal of Applied Earth Observation and Geoinformation*, vol. 113, p. 102990, sep. 2022, doi: 10.1016/J.JAG.2022.102990.
- [13] «Isla Graciosa». Accedido: 12 de febrero de 2024. [En línea]. Disponible en: <https://www.mapa.gob.es/es/pesca/temas/proteccion-recursos-pesqueros/reservas-marinas-de-espana/isla-graciosa/>
- [14] «Sebadales de La Graciosa». Accedido: 9 de enero de 2024. [En línea]. Disponible en: <https://www.miteco.gob.es/es/biodiversidad/temas/biodiversidad-marina/espacios-marinos-prottegidos/red-natura-2000-ambito-marino/zec-es7010020.html>
- [15] «Empleo de la tecnología LiDAR para el seguimiento ecológico: aplicación piloto para la Red de Parques Nacionales y comparativa con los datos LiDAR del PNOA ».
- [16] «Red Canaria de Espacios Naturales Protegidos - CanariWiki». Accedido: 12 de febrero de 2024. [En línea]. Disponible en: https://www3.gobiernodecanarias.org/medusa/wiki/index.php?title=Red_Canaria_de_Espacios_Naturales_Protegidos
- [17] «Parque Nacional de Timanfaya - CanariWiki». Accedido: 12 de febrero de 2024. [En línea]. Disponible en: https://www3.gobiernodecanarias.org/medusa/wiki/index.php?title=Parque_Nacional_de_Timanfaya
- [18] «Timanfaya: Campaña de eliminación de especies vegetales exóticas». Accedido: 21 de junio de 2024. [En línea]. Disponible en: <https://www.miteco.gob.es/es/parques-nacionales-oapn/red-parques-nacionales/parques-nacionales/timanfaya/conservacion-biodiversidad/exoticas.html>
- [19] «Biota - Rumex lunaria L.» Accedido: 17 de julio de 2024. [En línea]. Disponible en: <https://www.biodiversidadcanarias.es/biota/especie/F00295>

- [20] Escuela Politécnica de la Universidad de Extremadura, «Técnicas de oversampling aplicadas al análisis de imágenes hiperespectrales».
- [21] «Página de inicio | Copernicus». Accedido: 8 de mayo de 2024. [En línea]. Disponible en: <https://www.copernicus.eu/es>
- [22] «ESA - The Sentinel missions». Accedido: 9 de junio de 2024. [En línea]. Disponible en: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/The_Sentinel_missions
- [23] Karen. Fletcher y European Space Agency., *Sentinel-2 : ESA's optical high-resolution mission for GMES operational services*.
- [24] «Copernicus Browser». Accedido: 9 de mayo de 2024. [En línea]. Disponible en: <https://dataspace.copernicus.eu/browser/>
- [25] «WorldView-2 - Earth Online». Accedido: 18 de mayo de 2024. [En línea]. Disponible en: <https://earth.esa.int/eogateway/missions/worldview-2>
- [26] «WorldView Series - Earth Online». Accedido: 18 de mayo de 2024. [En línea]. Disponible en: <https://earth.esa.int/eogateway/missions/worldview>
- [27] DigitalGlobe, «THE BENEFITS OF THE EIGHT SPECTRAL BANDS OF WORLDVIEW-2», 2010.
- [28] T. Updike y C. Comp, «Radiometric Use of WorldView-2 Imagery Technical Note», 2010.
- [29] «Pika L - Hyperspectral Sensors - Benchtop Systems - Resonon». Accedido: 18 de mayo de 2024. [En línea]. Disponible en: <https://resonon.com/Pika-L>
- [30] «RedEdge-P dual - Drone Sensors | AgEagle Aerial Systems Inc.» Accedido: 1 de mayo de 2024. [En línea]. Disponible en: <https://ageagle.com/drone-sensors/rededge-p-dual-camera/>
- [31] «Zenmuse L1 - Cámaras cardán para drones - DJI Enterprise». Accedido: 1 de mayo de 2024. [En línea]. Disponible en: <https://enterprise.dji.com/es/zenmuse-l1>
- [32] J. Willneff y J. Poon, «GEOREFERENCING FROM ORTHORECTIFIED AND NON-ORTHORECTIFIED HIGH-RESOLUTION SATELLITE IMAGERY», 2006.
- [33] J. Martin, F. Eugenio, J. Marcello, A. Medina, J. A. Bermejo, y M. Arbelo, «Atmospheric correction models for high resolution WorldView-2 multispectral imagery: a case study in

- Canary Islands, Spain», <https://doi.org/10.1117/12.974564>, vol. 8534, pp. 153-162, nov. 2012, doi: 10.1117/12.974564.
- [34] D. Tanré, J. L. Deuzé, M. Herman, J. J. Morcrette, y S. Y. Kotchenova, «Second Simulation of a Satellite Signal in the Solar Spectrum-Vector (6SV)».
- [35] «Reserva marina del entorno de la isla de La Graciosa e islotes del norte de Lanzarote». Accedido: 19 de junio de 2024. [En línea]. Disponible en: https://www.gobiernodecanarias.org/pesca/temas/reservas_marinas/rrmm_la_graciosa.html
- [36] «Qué es ArcMap—ArcMap | Documentación». Accedido: 28 de junio de 2024. [En línea]. Disponible en: <https://desktop.arcgis.com/es/arcmap/latest/map/main/what-is-arcmap.htm>
- [37] «ENVI software avanzado en análisis geoespacial». Accedido: 28 de junio de 2024. [En línea]. Disponible en: <https://www.geospace-solutions.com/envi>
- [38] «NDWI: Fórmula Del Índice E Interpretación De Valores». Accedido: 12 de junio de 2024. [En línea]. Disponible en: <https://eos.com/es/make-an-analysis/ndwi/>
- [39] J. D. Hedley, A. R. Harborne, y P. J. Mumby, «Simple and robust removal of sun glint for mapping shallow-water benthos», *Int J Remote Sens*, vol. 26, n.º 10, pp. 2107-2112, may 2005, doi: 10.1080/01431160500034086.
- [40] «Giovanni». Accedido: 10 de junio de 2024. [En línea]. Disponible en: <https://giovanni.gsfc.nasa.gov/giovanni/>
- [41] «Ecocartografía de Las Palmas». Accedido: 6 de julio de 2024. [En línea]. Disponible en: <https://www.miteco.gob.es/es/costas/temas/proteccion-costa/ecocartografias/ecocartografia-laspalmas.html>
- [42] O. Kramer, «Dimensionality Reduction with Unsupervised Nearest Neighbors», *Intelligent Systems Reference Library*, vol. 51, 2013, doi: 10.1007/978-3-642-38652-7/COVER.
- [43] C. Zhang y Y. Ma, *Ensemble Machine Learning: Methods and Applications*. Springer Science & Business Media, 2012.
- [44] F. Eugenio, J. Marcello, J. Martin, y D. Rodríguez-Esparragón, «Benthic Habitat Mapping Using Multispectral High-Resolution Imagery: Evaluation of Shallow Water Atmospheric

- Correction Techniques», *Sensors* , vol. 17, n.º 11, p. 2639, nov. 2017, doi: 10.3390/S17112639.
- [45] F. Espino, F. Tuya, I. Blanch, y R. Haroun, *Los seadales de Canarias Oasis de vida en los fondos arenosos*. 2013.
- [46] L. Martín, G.-J. Barquín, D.-I. Tamia, y B. Izquierdo, «Bionomía bentónica de las Reservas Marinas de Canarias (España) Comunidades y hábitats bentónicos del infralitoral». [En línea]. Disponible en: www.mapama.gob.es
- [47] S. Suthaharan, «Machine Learning Models and Algorithms for Big Data Classification», vol. 36, 2016, doi: 10.1007/978-1-4899-7641-3.
- [48] «Parque Nacional de Timanfaya». Accedido: 21 de junio de 2024. [En línea]. Disponible en: <https://www.miteco.gob.es/es/parques-nacionales-oapn/red-parques-nacionales/parques-nacionales/timanfaya.html>
- [49] «Proyecto QGIS». Accedido: 28 de junio de 2024. [En línea]. Disponible en: <https://www.qgis.org/es/site/index.html>
- [50] «LASTools: converting, filtering, viewing, processing, and compressing LIDAR data in LAS and LAZ format». Accedido: 28 de junio de 2024. [En línea]. Disponible en: <https://lastools.github.io/>
- [51] C. Qian, C. Yao, H. Ma, J. Xu, y J. Wang, «Tree Species Classification Using Airborne LiDAR Data Based on Individual Tree Segmentation and Shape Fitting», *Remote Sensing 2023, Vol. 15, Page 406*, vol. 15, n.º 2, p. 406, ene. 2023, doi: 10.3390/RS15020406.
- [52] H. You, P. Lei, M. Li, y F. Ruan, «FOREST SPECIES CLASSIFICATION BASED ON THREE-DIMENSIONAL COORDINATE AND INTENSITY INFORMATION OF AIRBORNE LIDAR DATA WITH RANDOM FOREST METHOD», 2020, doi: 10.5194/isprs-archives-XLII-3-W10-117-2020.
- [53] X. Meng, N. Currit, y K. Zhao, «Ground Filtering Algorithms for Airborne LiDAR Data: A Review of Critical Issues», *Remote Sensing 2010, Vol. 2, Pages 833-860*, vol. 2, n.º 3, pp. 833-860, mar. 2010, doi: 10.3390/RS2030833.
- [54] C. Susetyo, «Comparison of Digital Elevation Modelling Methods for Urban Environment», *Journal of Engineering and Applied Sciences*, vol. 11, pp. 2957-2965, jun. 2016.

- [55] J. Xue y B. Su, «Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications», *J Sens*, vol. 2017, n.º 1, p. 1353691, ene. 2017, doi: 10.1155/2017/1353691.
- [56] «Introduction to Remote Sensing». Accedido: 24 de junio de 2024. [En línea]. Disponible en: <https://seos-project.eu/remotesensing/remotesensing-c01-p06.html>
- [57] A. J. Richardson y C. L. Wiegand, «Distinguishing vegetation from soil background information», *Photogramm Eng Remote Sensing*, vol. 43, 1977.
- [58] A. Muriel, J. Cortes, y J. Vargas, «Comparación cualitativa y cuantitativa de las técnicas básicas de umbralización global basadas en histogramas para el procesamiento digital de imágenes», *Scientia Et Technica*, vol. XVI, pp. 266-272, jul. 2011.

PLIEGO DE CONDICIONES

PLIEGO DE CONDICIONES

En este apartado se exponen requisitos técnicos utilizados en el desarrollo de este Trabajo Fin de Máster y sus características.

PC.1 CONDICIONES *HARDWARE*

En la Tabla PC.1 se muestran los dispositivos *hardware* necesarios para el desarrollo de este Trabajo Fin de Máster.

Tabla PC.1 Condiciones *hardware*.

Equipo/Dispositivo	Modelo	Fabricante
	Acer Aspire F15:	
	<ul style="list-style-type: none">• CPU Intel Core i7-7500U a 2,7 GHz.	
Ordenador personal	<ul style="list-style-type: none">• 16 GB RAM.• 512 GB SSD.• 2 puertos USB 3.0.• 1 puerto USB.	Acer Inc.

PC.1 CONDICIONES *SOFTWARE*

A continuación, se muestran las herramientas *software* empleadas para la realización de este TFM en la Tabla PC.2.

Tabla PC.2 Condiciones *software*.

Equipo/Dispositivo	Fabricante/Vendedor	Unidades
Sistema operativo Microsoft Windows 10	Microsoft Corporation	1
Herramienta ofimática Microsoft Office 2021	Microsoft Corporation	1
Imagen multiespectral satelital WorldView-2	DigitalGlobe	1
Imagen multiespectral satelital Sentinel-2	ESA	6
Imagen multiespectral Pika- L	TecnoFly Canarias	1
Imagen multiespectral MicaSense Dual	TecnoFly Canarias	1
Nube de puntos LiDAR Zenmuse L1	TecnoFly Canarias	1
Herramienta ArcMap	Esri	1
Interfaz PRIMO	GPIT	1
Herramienta ENVI	NV5 Geospatial Solutions	1
Herramienta QGIS	Equipo desarrollador QGIS	1

PRESUPUESTO

PRESUPUESTO

En este apartado, se detallan los gastos que conlleva el desarrollo de este Trabajo Fin de Máster. El presupuesto total se divide en los siguientes conceptos:

- Coste de recursos humanos.
- Coste de recursos *hardware*.
- Coste de recursos *software*.
- Coste de redacción del documento.
- Derechos de visado.
- Gastos de tramitación y envío.
- Coste Total.

P.1. RECURSOS HUMANOS

Para el cálculo del coste asociado a las horas de trabajo empleadas durante el desarrollo de este Trabajo Fin de Máster se utiliza una ecuación recomendada por el Colegio Oficial de Ingenieros de Telecomunicación (COIT), correspondiente al cálculo de honorarios en función de las horas trabajadas dentro y fuera de la jornada laboral convencional. La ecuación de los honorarios se presenta a continuación:

$$\text{Honorarios(€)} = C_t * (75 * H_n + 95 * H_e)$$

Donde las incógnitas corresponden a lo siguiente:

- El término C_t representa el factor de corrección que se aplica en función de las horas invertidas en el proyecto.
- El término H_n hace referencia al número de horas trabajadas dentro de la jornada laboral convencional.
- El término H_e representa el número de horas especiales u horas extra realizadas fuera de la jornada laboral.

Los valores del factor de corrección C_t se muestran en la Tabla P.1 de acuerdo con el procedimiento de cálculo marcado por el COIT:

Tabla P.1 Factor de corrección según las horas trabajadas.

Horas	Factor de corrección
Hasta 36	1,00
Desde 36 hasta 72	0,90
Desde 72 hasta 108	0,80
Desde 108 hasta 144	0,70
Desde 144 hasta 180	0,65
Desde 180 hasta 360	0,60
Desde 360 hasta 540	0,55
Desde 540 hasta 720	0,50
Desde 720 hasta 1080	0,45
Más de 1080	0,40

Las horas destinadas al desarrollo del Trabajo Fin de Máster son de 450 horas. Debido a esto, el factor de corrección tiene un valor de 0,55. Al utilizar la ecuación mostrada anteriormente el resultado es el siguiente:

$$\text{Honorarios(€)} = 0,55 * (75 * 450 + 95 * 0) = 18.562,50 \text{ €}$$

El coste asociado al tiempo invertido en términos de recursos humanos asciende a **DIECIOCHO MIL QUINIENTOS SESENTA Y DOS EUROS CON CINCUENTA CÉNTIMOS**.

P.2. RECURSOS MATERIALES

En este TFM han sido utilizadas tanto herramientas *hardware* como *software*. Para realizar el cálculo del coste de cada uno de estos recursos se relaciona su coste total con el tiempo útil de los mismos. Para realizar este cálculo se utiliza la siguiente ecuación, teniendo en cuenta que se fija como referencia para el sistema de amortización lineal una vida útil de 3 años:

$$Cuota = \frac{\text{Valor de la adquisición}}{\text{Amortización}} * \text{Tiempo de uso}$$

P.2.1. RECURSOS *HARDWARE*

En la Tabla P.2 se muestran los resultados del coste total de los recursos *hardware* utilizados en el desarrollo de este TFM.

Tabla P.2 Coste total de los recursos *hardware*.

Equipo/dispositivo	Valor de adquisición	Amortización	Coste mensual	Tiempo de uso	Importe
Ordenador personal – Acer Aspire	650 €	36 meses	18,05 €	6 meses	108,3 €

El coste total de los recursos *hardware* es de **CIENTO OCHO EUROS CON TREINTA CÉNTIMOS**.

P.2.2. RECURSOS *SOFTWARE*

En la Tabla P.3 se muestra el coste total de los recursos *software* utilizados en el desarrollo del presente TFM. Cabe destacar que varias de estas herramientas han sido proporcionadas de forma gratuita por la Universidad de Las Palmas de Gran Canaria (ULPGC).

Tabla P.3 Coste total de los recursos *software*.

Equipo/dispositivo	Valor de adquisición	Amortización	Coste mensual	Tiempo de uso	Importe
Sistema operativo					
Microsoft Windows 10	115 €	36 meses	3,19 €	6 meses	19,17 €
	0,00 €				
Microsoft Office	(licencia UPLGC)	36 meses	0,00 €	6 meses	0,00 €
Imagen multiespectral satelital WorldView-2	750€	-	-	-	750€
Imagen multiespectral satelital Sentinel-2	0,00 € (libre acceso)	-	-	-	0,00 €
Imagen hiperespectral dron Pika-L	3.000€	-	-	-	3.000€
Vuelo dron con sensor multiespectral MicaSense y sensor LiDAR Zenmuse L1	3.000€	-	-	-	3.000€
Campaña de campo	2.000€	-	-	-	2.000€
	0,00 €				
Herramienta ArcMap	(licencia UPLGC)	36 meses	0,00 €	6 meses	0,00 €
Interfaz PRIMO	0,00 € (GPIT)	36 meses	0,00 €	6 meses	0,00 €
Herramienta ENVI	3.200€	36 meses	88,89€	6 meses	533,33€
Herramienta QGIS	0,00 € (libre acceso)	36 meses	0,00 €	6 meses	0,00 €
Coste total					9.302,50 €

El coste total de los recursos *software* es de *NUEVE MIL TRESCIENTOS DOS EUROS CON CINCUENTA CÉNTIMOS*.

P.3. REDACCIÓN DEL TRABAJO

Partiendo del presupuesto calculado previamente, se pueden calcular los costes asociados a la redacción de la memoria de este TFM a partir de la siguiente fórmula:

$$R = 0,07 * P * C_n$$

Donde las incógnitas representan lo siguiente:

- El término R representa los honorarios derivados de la redacción del trabajo.
- El término P hace referencia al presupuesto del trabajo.
- El término C_n representa el coeficiente de corrección en función del presupuesto calculado.

El valor del presupuesto (P) se obtiene mediante la suma del coste relativo a los RRHH y los recursos materiales, tanto *hardware* como *software*, como muestra la siguiente ecuación:

$$P = 18.562,50 + 108,3 + 9.302,50 = 27.973,3 \text{ €}$$

Según el COIT, el coeficiente de corrección C_n tendrá valor 1 si P tiene un valor inferior a los 30.050,00 €. Por lo tanto, la ecuación queda de la siguiente forma:

$$R = 0,07 * 27.973,3 * 1 = 1.958,13 \text{ €}$$

El coste derivado de la redacción del presente Trabajo Fin de Máster es de *MIL NOVECIENTOS CINCUENTA Y OCHO EUROS CON TRECE CÉNTIMOS*.

P.5. DERECHOS DE VISADO DEL COIT

El COIT proporciona anualmente valor a los costes asociados a los derechos de visado por la ejecución de proyectos técnicos de carácter general. Para el año 2024 estos costes se calculan de la siguiente manera:

$$V = 0,006 * P_1 * C_1 + 0,003 * P_2 * C_2$$

Donde estas incógnitas representan lo siguiente:

- El término V es el coste final del visado.
- El término P_1 representa el presupuesto del proyecto.
- El término C_1 hace referencia al coeficiente reductor en función del presupuesto.
- El término P_2 representa el presupuesto de ejecución material correspondiente a la obra civil.
- El término C_2 hace referencia al coeficiente de corrección en función del presupuesto P_2 .

En este TFM, se puede determinar que el coste asociado al presupuesto P_2 es igual a 0,00 € por lo que no será necesario aplicar el coeficiente C_2 . Respecto al coeficiente C_1 , como el presupuesto P_1 no supera los 30.050,00 €, tiene un valor igual a 1. En este caso se suma al presupuesto P_1 el coste asociado a la redacción del trabajo, por lo que se obtienen un valor total de 29.931,43€. La ecuación quedaría de la siguiente manera:

$$V = 0,006 * 29.931,43 * 1 = 179,59 \text{ €}$$

El coste asociado a los derechos de visado del presupuesto es de *CIENTO SETENTA Y NUEVE EUROS CON CINCUENTA Y NUEVE CÉNTIMOS*.

P.6. GASTOS DE TRAMITACIÓN Y ENVÍO

Los gastos de tramitación y envío suponen *SEIS EUROS* (6 €) por cada documento visado.

P.7. COSTE TOTAL DEL PROYECTO

Una vez obtenidos todos los costes asociados a las diferentes actividades que forman parte del desarrollo de este TFM, se puede obtener el coste total del proyecto. A este proyecto se le aplica el Impuesto General Indirecto Canario (IGIC) del siete por ciento (7%). El coste final del proyecto se muestra en la Tabla P.4.

Tabla P.4 Coste total del Trabajo Fin de Máster.

Concepto	Coste
Honorarios por tiempo empleado	18.562,50 €
Recursos hardware	108,3 €
Recursos software	9.302,50 €
Costes de redacción	1.958,13 €
Derechos del visado del COITT	179,59€
Costes de tramitación y envío	6,00 €
Subtotal	30.117,02 €
IGIC (7%)	2.108,19 €
Coste total	32.225,21 €

El presupuesto final del Trabajo Fin de Máster “Procesado y aplicación de tecnologías multiplataforma para monitorización marina y terrestre” es de *TREINTA Y DOS MIL DOSCIENTOS VEINTICINCO EUROS CON VEINTIÚN CÉNTIMOS*

Fdo.: D. Daniel Baute Trujillo

En Las Palmas de Gran Canaria a 17 de julio de 2024