

TESIS DOCTORAL

APLICACIÓN DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO
A LA MONITORIZACIÓN DE LA CALIDAD DE MASAS DE
AGUA MEDIANTE TÉCNICAS DE TELEDETECCIÓN

PhD THESIS

APPLICATION OF MACHINE LEARNING TECHNIQUES TO
WATER QUALITY MONITORING BY REMOTE SENSING

AUTOR

DANIEL GARCÍA DÍAZ

DIRECTORES

JESÚS MARCO DE LUCAS

FERNANDO AGUILAR GÓMEZ

UNIVERSIDAD DE CANTABRIA

Escuela de **Doctorado** de la Universidad de Cantabria

Santander 2022

Agradecimientos

No puedo empezar estas líneas sino dando las gracias en primer lugar a mis directores, Jesús Marco y Fernando Aguilar, quienes con su ayuda y motivación han hecho posible esta tesis. Gracias por darme la oportunidad de pasar estos años trabajando y aprendiendo a vuestro lado. También me gustaría dar las gracias a todos mis compañeros del grupo de Computación Avanzada y e-Ciencia del Instituto de Física de Cantabria: Lara, Aída, Miguel Ángel, Maria, Álvaro, Diana, Pablo, Ivan, ... y en especial a Ignacio, pues de todos ellos he recibido apoyo y de todos he aprendido varias de las cosas que hacen que hoy esté aquí. Gracias también al resto de miembros del departamento y del Instituto de Física de Cantabria.

Gracias al equipo de Ecohydros S.L y en especial a Agustín y a Alberto, pues en esta tesis también hay parte de su trabajo y esfuerzo.

Dedicar este trabajo a quienes con su apoyo incondicional e imprescindible lo han hecho posible. A Rocío y Leo, porque vosotros habéis escrito conmigo cada una de estas líneas. A mis padres, Jose Miguel y Rosario, por que ellos pusieron la primera piedra con mi educación personal. A Toño, amigo y aliado desde el primer día de facultad.

Resumen

Esta tesis aborda el problema de la monitorización de la calidad de las masas de agua continentales y los episodios de eutrofización a los que éstas pueden verse sometidos mediante los datos de teledetección espacial publicados en abierto por la Agencia Espacial Europea (European Space Agency, ESA) y la NASA (National Aeronautics and Space Administration) para sus misiones espaciales Sentinel-2 y Landsat 8 respectivamente.

En este trabajo se introducen recientes técnicas de aprendizaje automático, como son los algoritmos de deep learning, tanto en el preprocesado de las imágenes como en la inferencia de las variables de calidad de agua a monitorizar. Gracias a estas técnicas se propone con éxito un nuevo método para monitorizar la temperatura y la concentración de clorofila de un embalse eutrofizado durante los años 2018-2022, estimando ambas variables de forma fiable tanto temporal como espacialmente.

En el caso de la temperatura se corrigieron las desviaciones observadas al estimar la temperatura mediante la ecuación de transferencia radiativa gracias a una regresión lineal que utiliza las mismas bandas térmicas del satélite Landsat 8. Este modelo consigue un error inferior a $1^{\circ}C$, y es capaz de estimar la temperatura superficial del agua durante tres años cuando se ha calibrado durante un único año, y en las diferentes zonas del embalse con datos recogidos en un único punto de este.

Para inferir las medidas de concentración de clorofila en el embalse se optó por un planteamiento más original, entrenando una red neuronal mediante medidas in-situ realizadas simultáneamente con los pasos de los satélites Sentinel-2A/B. Se utilizan los espectros de reflectancia recogidos por las bandas del sensor MSI del satélite Sentinel-2 dentro del rango de 400-800 nm, para estimar la concentración de clorofila. Estos nuevos métodos de aprendizaje automático son capaces de evaluar el espectro completo y extraer la información subyacente en los datos para distinguir diferentes distribuciones asignando una concentración determinada.

Gracias a ello, esta red neuronal clasifica correctamente los valores de concentración muy baja, baja y media, con una incertidumbre aproximada del 10 %, y es capaz de extender esta estimación tanto en el tiempo, durante dos años, como en el espacio, estimando la concentración en las diferentes zonas del embalse cuando ha sido calibrado en un único punto de éste y únicamente con los datos recogidos en esos dos años.

La introducción de los nuevos métodos de aprendizaje automático se aplica también en el preprocesado de las imágenes satelitales, y más concretamente en el proceso de pansharpening o “fusión” de imágenes. En este apartado se utiliza una técnica novedosa en el estado del arte la cual utiliza redes neuronales convolucionales con el fin de incrementar de forma fiable la calidad espacial de los datos satelitales.

Para las correcciones atmosféricas pertinentes se optó por utilizar el software ACOLITE, particularmente desarrollado para el procesamiento de aguas turbias y masas de agua continentales. Este software ha demostrado tener un mejor rendimiento que otros procesadores gracias en parte a la corrección del destello solar aplicada.

El resultado final es un sistema automático de monitorización del estado trófico de las masas de agua dulce a través de la concentración de clorofila-a, el cual utiliza únicamente los datos en abierto proporcionados por los principales satélites operativos.

Abstract

This thesis addresses the problem of monitoring the quality of continental water masses and the eutrophication episodes through space remote sensing data published openly by the European Space Agency (ESA) and NASA (National Aeronautics and Space Administration) for their Sentinel-2 and Landsat 8 space missions respectively.

In this work, recent automatic learning techniques are introduced, both in the preprocessing of the images and the inference of the water quality variables to be monitored. Thanks to these techniques, a new method is successfully proposed to monitor the temperature and chlorophyll concentration of a eutrophic reservoir during the years 2018-2022, estimating both variables reliably both temporally and spatially.

In the case of temperature, the deviations observed when estimating the temperature were corrected using the radiative transfer equation thanks to a linear regression that uses the same thermal bands as the Landsat 8 satellite. This model achieves an error of less than $1^{\circ}C$, and is capable of estimating the surface temperature of the water for three years when it has been calibrated for a single year, and in the different areas of the reservoir with data collected at a single point in the reservoir.

To infer the chlorophyll concentration measurements in the reservoir, a more innovative approach was chosen, training a neural network through in-situ measurements carried out simultaneously with the passages of the Sentinel-2A/B satellites. The reflectance spectra collected by the bands of the MSI sensor of the Sentinel-2 satellite within the range of 400-800 nm are used to estimate the concentration of chlorophyll. These new machine learning methods are capable of evaluating the full spectrum and extracting the underlying information in the data to distinguish different distributions by assigning a certain concentration.

This neural network correctly classifies the values of very low, low and medium concentration, with an approximate uncertainty of 10%, and is capable of extending this estimate both in time, over two years, and in space, estimating the concentration in the different areas of the reservoir when it has been calibrated at a single point of the reservoir and only with the data collected during two years.

The introduction of new automatic learning methods is also applied to the pre-processing of satellite images, and more specifically in the process of pansharpening or “fusion” of images. In this section, a novel technique in the state of the art is used, which uses convolutional neural networks to reliably increase the spatial quality of satellite data.

To apply the atmospheric corrections, it was decided to use the ACOLITE software, particularly developed for the processing of turbid waters and continental water masses. This software has been shown to perform better than other processors thanks in part to applied sun flare correction.

The final result is an automatic system for monitoring the trophic state of freshwater masses through the concentration of chlorophyll-a, which only uses open data provided by the main operational satellites.

Índice general

Introducción	xvii
Objetivos	xxi
Descripción y Estructura del Informe	xxii
1. Teledetección	1
1.1. Introducción	1
1.2. Fundamentos de la teledetección satelital	3
1.2.1. Conceptos básicos	3
1.2.2. El espectro electromagnético	5
1.2.3. Interacción de la radiación con la superficie de la Tierra	7
1.2.4. Firmas Espectrales	8
1.2.5. Efecto de la atmósfera sobre la radiación electromagnética	10
1.3. Características de la teledetección	14
1.3.1. Resolución de una imagen multispectral	14
1.3.2. Tipos de imagen de teledetección	18
1.4. Correcciones de la imagen	20
1.4.1. Correcciones radiométricas	21
1.4.2. Corrección del bandeo de la imagen	22
1.4.3. Correcciones geométricas o georreferenciación	24
1.4.4. Correcciones atmosféricas	26
1.5. Plataformas espaciales de Teledetección	29
1.5.1. Misión LANDSAT	29
1.5.2. Programa Copernicus y misiones Sentinel	35

2. Masas de Agua Continentales y Teledetección	41
2.1. Detección de las Masas de Agua Continentales	45
2.2. Monitorización de la calidad del agua	48
2.2.1. Clorofila	50
2.2.2. Concentración de sustancias orgánicas disueltas	52
2.2.3. Turbidez	53
2.2.4. Temperatura	55
3. Propiedades ópticas del agua en el embalse de “El Val”	57
3.1. Embalse de El Val (Zaragoza)	58
3.2. Estudio Espectroscópico	64
3.2.1. Ley de Beer-Lambert	67
3.2.2. Estudio Espectrofotométrico	69
3.3. Conclusiones	82
4. Preprocesado de imágenes	85
4.1. Fusión de imágenes	85
4.1.1. Algoritmos de Fusión	88
4.1.2. Evaluación de los algoritmos de fusión de imágenes	94
4.1.3. Conclusiones	115
4.2. Corrección atmosférica	116
4.2.1. Algoritmos de corrección atmosféricas	118
4.2.2. Correcciones atmosféricas aplicadas	122
5. Monitorización del embalse de “El Val” mediante teledetección	125
5.1. Estimación de la temperatura mediante	
teledetección	133
5.1.1. Datos in-situ	133
5.1.2. Metodología para la estimación de la temperatura	
superficial mediante teledetección	136
5.1.3. Correcciones atmosféricas	139
5.1.4. Resultados en la estimación de la temperatura	140
5.1.5. Conclusiones sobre la estimación de la temperatura	159

5.2. Estimación de la turbidez y la concentración de clorofila-a	161
5.2.1. Turbidez	161
5.2.2. Clorofila	167
5.2.3. Conclusiones	195
6. Conclusiones	197
6.1. Método y resultados en el embalse	198
6.2. Debilidades y fortalezas del desarrollo	200
6.3. Líneas de continuación futuras	201
6.3.1. Validación cruzada con medidas en otros embalses	201
6.3.2. Nuevo enfoque de los algoritmos de aprendizaje automático en la teledetección	202
6.4. Sensor para aplicaciones de calidad de agua continentales	202
Anexos	221
Anexo A	221
Intensidad-matiz-saturación, IHS	221
Método de Brovey	222
Filtro Paso alto, HPF	223
Transformada discreta de Wavelet	226
Anexo B	230
ERGAS espectral	230
ERGAS espacial	231
Anexo C	232

Introducción

Los primeros datos de los que se tienen constancia en la historia de la teledetección datan de 1859 y provienen del primer globo aerostático utilizado para captar fotografías aéreas de la Tierra [1]. El objetivo fue fotografiar el bosque de Boulogne y el Arco del Triunfo, y la conclusión derivada fue que esta técnica también se podía aplicar a los levantamientos topográficos y catastrales. También se usaban palomas mensajeras, cometas y globos no tripulados para tomar imágenes, aunque a excepción de las tomadas por los globos, estas primeras imágenes no fueron muy útiles para diseñar mapas, ni para realizar investigaciones científicas.

Actualmente, el término teledetección se refiere de manera general, a la técnica empleada para adquirir información a pequeña o gran escala de un objeto o área concreta, utilizando sensores que no están en contacto directo con el objeto a medir. Algunos de los dispositivos utilizados más conocidos son: las cámaras fotográficas, las cámaras multiespectrales, o los radares que se instalan en aviones, satélites, barcos, etc.

Las principales ventajas que aporta la teledetección son su elevada capacidad para tomar datos a gran escala y transmitirlos en tiempo real o cuasi-real, reduciendo costes y reemplazando la lenta y costosa recogida de información sobre el terreno, haciendo además posible recoger información de áreas peligrosas o de difícil acceso.

Estas ventajas se hacen más evidentes cuando hablamos de la observación de la Tierra mediante teledetección desde el espacio. El programa Landsat, que se inició en 1972 con el lanzamiento del Landsat 1, fue el primero en enviar un satélite de observación de la Tierra al espacio, con la intención expresa de estudiar y monitorizar la superficie terrestre [2].

El mismo año se lanzó también la primera estación espacial, Skylab, la cual se utilizó para observaciones solares y también para experimentos detallados de mapeo de recursos terrestres, y en los años siguientes se lanzarían muchas más misiones con sensores cada vez más especializados y diseñados en función de la superficie a estudiar. Algunos ejemplos: Meteosat-1, el primero de una larga serie de satélites meteorológicos europeos, Seasat-1, el primer satélite civil de radar de apertura sintética (SAR, Synthetic Aperture Radar) o Nimbus-7, con sensor de mapeo de ozono total en la atmósfera, y escáner de color de la zona costera [1].

Los satélites abrieron un nuevo abanico de posibilidades en el mundo de la teledetección, ya que permitieron realizar observaciones desde mayor altura y adquirir datos de forma periódica, favoreciendo así la monitorización, a corto y largo plazo, de los cambios medioambientales y del impacto de la actividad humana en la superficie terrestre. Algunas de las aplicaciones más interesantes de esta tecnología actualmente son la evaluación de cambios globales como la deforestación, la desaparición de la capa de ozono, la monitorización y gestión de recursos naturales, la vigilancia de incendios, las predicciones meteorológicas, etc [3].

La aplicación de la teledetección a la monitorización de los recursos naturales de la Tierra se fundamenta en las propiedades de la radiación electromagnética procedente del sol y en su interacción con los materiales de la superficie terrestre [4]. Debido a que todos los materiales de la naturaleza tienen una respuesta espectral propia, denominada *signatura espectral*, el objetivo es su identificación a través de la misma.

Aunque la teledetección ofrece grandes posibilidades para realizar progresos en el conocimiento de la naturaleza, y aunque esta técnica se ha empleado en muchas y muy diversas aplicaciones a lo largo de la historia, ha sido en la última década cuando su uso se ha generalizado y se han diseñado aplicaciones para casi todas las ramas de las ciencias de la Tierra.

Una de las claves que explican el auge de la teledetección, y que está directamente relacionada con el desarrollo de la computación en los últimos años, es la sustancial mejora de los diferentes algoritmos de aprendizaje automático, entre los que se encuentran los métodos de clasificación supervisados y no supervisados. Destacan las mejoras de las máquinas de vector soporte (Support Vector Machines, SVM) y los métodos de clustering, y especialmente las redes neuronales artificiales (Artificial Neural Network, ANN).

Si bien muchas de estas técnicas no son realmente nuevas, muchos de los avances que se producían en el pasado en esta materia habían sido de limitada utilidad debido a las limitaciones computacionales existentes. En la actualidad, sin embargo, con el incremento en las capacidades de procesamiento de los sistemas de computación, las técnicas de big data y los servicios en línea en la nube (Cloud Computing), los cuales mejoran la accesibilidad y el tratamiento de los datos, se ha logrado acelerar y extender su aplicación.

La visión por computador se ha vuelto omnipresente en nuestra sociedad y el núcleo de muchas de estas aplicaciones son las tareas de reconocimiento visual tales como la clasificación, localización y detección de imágenes. Los desarrollos recientes en las técnicas de aprendizaje automático han avanzado enormemente en el rendimiento de estos sistemas de reconocimiento visual de última generación, permitiendo a su vez avanzar en el campo de la teledetección.

La segunda clave la encontramos en los avances tecnológicos que se han producido en los sensores utilizados en teledetección y en las resoluciones espaciales y temporales ahora disponibles.

El programa Copernicus de la ESA [5], por ejemplo, uno de los programas de observación de la Tierra más ambicioso de la historia, fue diseñado para proporcionar información precisa y de fácil acceso, orientada especialmente a mejorar la gestión del medio ambiente. Además de un gran número de sensores en Tierra que toman medidas in-situ de validación, el programa Copernicus consta de cinco familias de satélites, los Sentinel, que proporciona un conjunto único de observaciones.

Por su parte, la NASA puso en órbita en 2013 el satélite Landsat 8 [6], diseñado para continuar con el programa de captura global de imágenes espaciales que los Estados Unidos han estado implementando.

La calidad de la información empleada en teledetección depende de las resoluciones espacial, espectral, radiométrica y temporal de los datos, y con las últimas misiones lanzadas por la ESA y la NASA, equipados con la última tecnología en sensores multispectrales, disponemos de una cantidad de datos sin precedentes.

Actualmente se estima que la población mundial es de 8.000 millones de personas, y se espera que aumente en 2.000 millones en los próximos 30 años, pasando de los 8.000 millones a los 10.000 millones en 2050, pudiendo llegar a un pico de cerca de 11.000 millones para 2100 [7]. Este aumento conlleva numerosas implicaciones para la planificación y gestión de los recursos hídricos del planeta.

Si además añadimos que se espera que el cambio climático modifique el ciclo del agua incluyendo las precipitaciones, la humedad del suelo, la escorrentía, la evaporación, el vapor atmosférico y la temperatura del agua [8], podemos concluir que la gestión de los recursos hídricos a nivel mundial requiere por tanto, de nuevas soluciones para contrarrestar los crecientes desafíos. Los datos procedentes de la teledetección son una gran fuente de información y pueden desempeñar un importante papel en la consecución de este objetivo.

Este trabajo se centra en explorar el potencial de las nuevas técnicas para el análisis de datos en la teledetección en general y especialmente en la gestión de los recursos hídricos de la Tierra, monitorizando la calidad de las masas de agua continentales, como son los lagos y embalses, y utilizando para ello datos de las misiones Sentinel y Landsat.

El desarrollo de esta tesis ha sido posible gracias a la conjunción de varios factores. En primer lugar, la experiencia y disponibilidad de expertos en aprendizaje automático dentro del grupo de computación avanzada y e-Ciencia del IFCA (Instituto de Física de Cantabria). En segundo lugar, la oportunidad de abordar un problema concreto, el de la calidad del agua en el embalse del Val, dentro de un proyecto de colaboración con una PYME, Ecohydros. Y en tercer lugar, contar con la participación en la Plataforma Temática Interdisciplinar Teledetect, que ha propiciado un entorno de análisis y discusión de técnicas y resultados en el área.

Objetivos

El primer objetivo de este trabajo es analizar y resumir el estado del arte de la teledetección espacial, centrandolo este estudio en las técnicas empleadas hasta el momento en la monitorización de las masas de agua. La teledetección está ya extendida en campos como los estudios agrícolas o las predicciones meteorológicas, pero su uso en la monitorización de masas de agua continentales es relativamente nuevo.

El segundo objetivo, directamente relacionado con el primero, es revisar cómo pueden ser estudiados y monitorizados mediante teledetección los parámetros que influyen en la calidad del agua, las variables ópticamente activas (OAC), que pueden ayudarnos a determinar el estado trófico de las masas de agua. Hasta la fecha se han planteado diversos índices de estado trófico en función de la concentración de clorofila y la turbidez.

El tercer objetivo es aplicar a este campo las últimas técnicas empleadas en inteligencia artificial como son las técnicas de aprendizaje automático. Es común que aplicaciones desarrolladas para analizar datos procedentes de teledetección todavía utilicen los conceptos básicos de procesamiento de imágenes, desarrollados a principios de los años setenta, realizándose la clasificación de los píxeles de manera individual en un espacio multidimensional, o utilizando únicamente la segmentación de la imagen basándose en técnicas de detección de bordes o segmentación basada en regiones.

Las nuevas resoluciones espectrales y espaciales, y sobre todo, la cantidad de datos ahora disponibles, abren la puerta a nuevas formas de monitorizar las masas de agua continentales aplicando a estos datos los últimos avances en minería de datos, como son las técnicas de aprendizaje profundo basadas en redes neuronales convolucionales.

El objetivo general, que engloba todos los anteriores, es desarrollar un sistema de estudio y monitorización de las masas de agua dulce mediante los datos en abierto proporcionados por los principales satélites operativos.

Además, como propuesta de futuro, se propondrán las características necesarias que deben tener los sensores a instalar en los satélites, para mejorar la monitorización de la calidad de masas de agua continentales.

Estructura

El trabajo se ha estructurado de acuerdo a los objetivos marcados en la sección anterior y se ha dividido en seis capítulos de la siguiente forma:

El primer capítulo proporciona una visión global de la teledetección satelital, en la que se han expuesto tanto los fundamentos teóricos de esta técnica, como las características especiales de los datos que se utilizan. También se han introducido las misiones satelitales con las que se ha trabajado a lo largo de este proyecto.

En el capítulo 2, se repasa el estado del arte de la monitorización de la calidad de las masas de agua continentales mediante teledetección satelital. Para ello, se ha revisado el proceso de eutrofización de las masas de agua, la clasificación de los diferentes estados tróficos, los parámetros que se consideran para dicha clasificación, las características de los espectros de reflexión que permiten determinar dichos parámetros, y los métodos de detección que se han empleado.

En el capítulo 3 se presenta un estudio espectrofotométrico de las propiedades ópticas del agua bajo diferentes valores de los parámetros que estiman su calidad. Este estudio se ha realizado empleando muestras de agua y tomadas in-situ en el embalse del Val. Se incluye por ello una descripción detallada del área de estudio y el embalse.

El capítulo 4 se emplea para explicar el pre-procesado realizado a las imágenes satelitales con las que se ha trabajado, antes de estimar específicamente los parámetros físicos o biológicos. Este preprocesado incluye: técnicas para mejorar la resolución espacial, la precisión y la fiabilidad de los datos, las correcciones atmosféricas aplicadas, etc. El preprocesado es vital para mejorar la calidad de nuestros datos y la precisión del método.

En el capítulo 5 se presentan los algoritmos desarrollados en este trabajo para estimar los parámetros de calidad de agua, y los resultados obtenidos mediante estos algoritmos en comparación con los resultados obtenidos por otros métodos de última generación. En este capítulo se estudia tanto la coherencia temporal de las parámetros estimados, analizando series temporales a lo largo de varios años correspondientes a un mismo punto de medición, como la coherencia espacial, mediante mapas bidimensionales de estos mismos parámetros validados con medidas in-situ en distintos puntos del embalse.

Por último, en el capítulo 6, se presentan las conclusiones de la tesis, así como posibles líneas de trabajo futuras y un breve resumen de las características que, según lo aprendido en este trabajo, deben cumplir los sensores a instalar en los satélites para mejorar la monitorización de las masas de agua continentales.

Capítulo 1

Teledetección

1.1. Introducción

Debido al desarrollo de la teledetección en los años precedentes, en 2004 arrancó en España el Plan Nacional de Teledetección, *“un proyecto integrado dentro del Plan Nacional de Observación del Territorio, con la idea de aunar esfuerzos, tanto económicos como de gestión entre las distintas administraciones públicas españolas para la adquisición de coberturas nacionales con imágenes de satélite de distintas resoluciones espaciales”* [3]. El objetivo de este plan, aún vigente, es disponer de manera sistemática de imágenes de satélite del territorio español, y por ello, desde el año 2005 se adquieren y procesan imágenes de distintos satélites comerciales con distintos tamaños de píxel.

Desde el comienzo se impulsó el uso masivo de imágenes satelitales en múltiples proyectos y aplicaciones entre las que se encuentran [3]:

- Gestión de recursos hídricos y de regadíos.
- Balance de carbono y flujos de CO_2 .
- Agricultura de precisión.
- Planes de infraestructuras (PEIT).
- Sistemas de información de ocupación del suelo (SIOSE), agrícolas (SIGPAC) y forestales (MFE).

- Seguimiento de humedales, producción de pastos.
- Riesgo de incendios.
- Actualización de bases de datos cartográficas.

El uso de imágenes satelitales se extendió en el año 2008 con la puesta a disposición de imágenes del programa Landsat bajo una licencia libre y abierta, aunque la verdadera generalización de la teledetección espacial llegó en los años 2014 y 2015, con los lanzamientos del satélite radar Sentinel-1A y el satélite multispectral Sentinel-2A respectivamente, pertenecientes ambos al programa Copernicus de la ESA.

Actualmente, y gracias a programas como éste, se pueden llevar a cabo estudios o seguimientos a partir de las imágenes de satélite en los anteriores campos y en otros como el estudio de la atmósfera y el clima, sismología y vulcanología, riesgos naturales, hidrología, urbanismo, oceanografía, geología, arqueología, biodiversidad y paisaje. Entre los ejemplos concretos más importantes y conocidos de estas aplicaciones están: el estudio de los humedales y de los usos del suelo en la comarca de Doñana y su entorno [9], o el seguimiento de los humedales de la Albufera de Valencia [10].

Otros ejemplos más recientes y de elevado impacto social son el estado de las inundaciones y el seguimiento de su evolución, como las provocadas por el río Ebro en la primavera de 2018 a su paso por Alcalá de Ebro en la provincia de Zaragoza, o la detección y seguimiento de incendios como el incendio del 24 de agosto de 2019 en la isla de Gran Canaria [11].

Desde el Consejo Superior de Investigaciones Científicas (CSIC), consciente de la importancia de la teledetección, se están promoviendo acciones en este área como la Plataforma Temática Interdisciplinar de Teledetección (“PTI Teledetect”)¹ que tiene como objetivos: *“Coordinar e integrar las actividades de teledetección del CSIC en un polo de conocimiento común y crear una estructura que dé una respuesta efectiva a las necesidades de la sociedad, industria y administraciones”*.

¹<https://pti-teledetect.csic.es/>

1.2. Fundamentos de la teledetección satelital

1.2.1. Conceptos básicos

Una definición general de Teledetección es: *“la ciencia y la tecnología por medio de la cual se pueden identificar las características de los objetos de interés, medirlos o analizar sus características sin contacto directo”* [12]. La información que se detecta mediante esta técnica es, por tanto, debido a la interacción que existe entre el objeto y los sensores, y esta interacción puede ser del tipo electromagnético, por ondas acústicas, o incluso por perturbaciones del campo gravitatorio.

La teledetección espacial a través de satélite se basa en la medición de la energía electromagnética que es emitida o reflejada desde la superficie de la Tierra, y captada mediante sensores a bordo de satélites. Se pueden distinguir dos tipos principales:

- **Teledetección Pasiva:** Los sensores en estos satélites detectan la radiación natural emitida o la luz solar reflejada por el objeto o superficie que está siendo observada. Las placas fotográficas fueron el sensor inicial, aunque después se han incorporado diferentes tipos como son los sensores CMOS o las CCDS.
- **Teledetección Activa:** El satélite emite radiación electromagnética para detectar los objetos midiendo la radiación reflejada. El radar es un ejemplo muy conocido de teledetector activo, el cual emitiendo ondas de radio y midiendo el tiempo que tarda la emisión en reflejarse en el objeto, puede establecer su localización, dimensión y desplazamiento.

Los sistemas de teledetección de la superficie terrestre (figura 1.1) están típicamente compuestos de los siguientes elementos [13]:

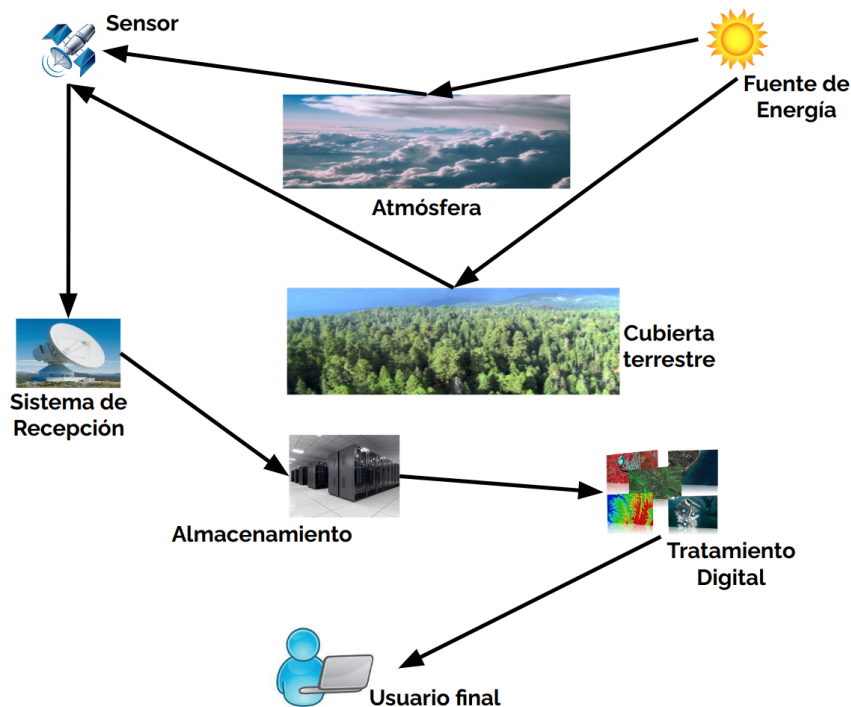


Figura 1.1: Esquema básico de los componentes de un sistema de teledetección.

- **Fuente de energía:** El origen de la energía electromagnética que detecta el sensor. Depende del tipo de teledetección, puede ser un foco externo al sensor (pasiva), o de un haz emitido por este (activa).
- **Cubierta Terrestre:** La vegetación, suelo, rocas, construcciones, masa de agua, etc. que reflejan o emiten la energía hacia el sensor.
- **Sistema sensor:** Compuesto por el sensor propiamente dicho (cámara o radar) y la plataforma que lo alberga (satélite, avión, globo). Capta la energía proveniente de la cubierta terrestre y la almacena o la envía directamente al sistema de recepción.
- **Sistema de recepción:** Donde se recibe la información transmitida por el sistema sensor.
- **Sistema de almacenamiento y Tratamiento digital:** Analiza la información, convirtiéndola en una clave temática o cuantitativa, orientada a facilitar la evaluación del problema. Se prepara la información para la difusión entre los usuarios.
- **Usuario final:** El beneficiario del documento o dato una vez analizado por el intérprete.

1.2.2. El espectro electromagnético

La utilización más usual del término teledetección se realiza en referencia a las técnicas empleadas para adquirir y procesar información electromagnética procedente de la superficie terrestre. Estas técnicas abarcan el conjunto del espectro electromagnético desde las ondas de radio de baja frecuencia, a la radiación ultravioleta, pasando por las regiones de las microondas, infrarrojo, visible, etc.

Se denomina espectro electromagnético (figura 1.2) al sistema que clasifica, según las longitudes de onda, el conjunto de las ondas electromagnéticas.




Figura 1.2: Esquema del espectro electromagnético [14].

Desde el punto de vista de la teledetección satelital actual conviene destacar una serie de bandas espectrales que son las que con más frecuencia se emplean. La denominación y la amplitud de estas pueden variar según distintos autores, si bien la terminología comúnmente aceptada es [13]:

- Espectro visible ($400 - 800 \text{ nm}$).
- Infrarrojo cercano ($0.8 - 1.1 \mu\text{m}$).
- Infrarrojo medio ($1.1 - 8 \mu\text{m}$).
- Infrarrojo lejano ($8 - 14 \mu\text{m}$).
- Microondas ($30\text{cm} - 10\text{mm}$).

1.2.3. Interacción de la radiación con la superficie de la Tierra

La energía electromagnética al interactuar con la superficie terrestre puede sufrir diferentes procesos, y puede descomponerse en tres factores diferentes. Una parte de la energía incidente es reflejada, mientras que el resto penetra en los elementos de la superficie terrestre y se descompone en energía absorbida y energía transmitida (figura 1.3) [13].

$$E_i = E_r + E_a + E_t \quad (1.1)$$

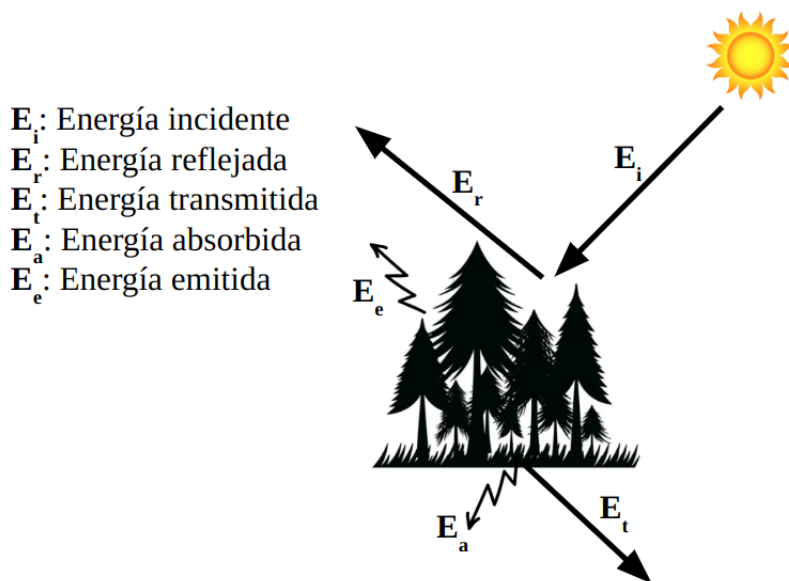


Figura 1.3: Esquema del proceso que sufre la Energía electromagnética en la superficie de la Tierra. Adaptada de [13].

Las proporciones de energía reflejada, absorbida y transmitida varían para cada objeto, lo que resulta muy interesante y hace posible la discriminación e identificación de las distintas superficies mediante los sistemas de teledetección. Además, para un mismo objeto, estas proporciones varían con la longitud de onda, por lo que dos objetos pueden no ser distinguibles en una porción del espectro y perfectamente diferenciables en otra.

En el caso del espectro visible, este comportamiento de los objetos a distintas longitudes de onda es lo que nos permite hablar del color de los objetos. Un objeto es azul, cuando refleja intensamente la energía en esa banda, y absorbe el resto. Del mismo modo, el objeto será verde si su reflectividad es alta en esa banda y baja en otras.

1.2.4. Firmas Espectrales

A la dependencia de la reflectancia como función de la longitud de onda, se le denomina curva de reflectancia espectral o firma espectral (figura 1.4). Cada material tiene una firma única, y por lo tanto, se puede utilizar para la clasificación de materiales [15].

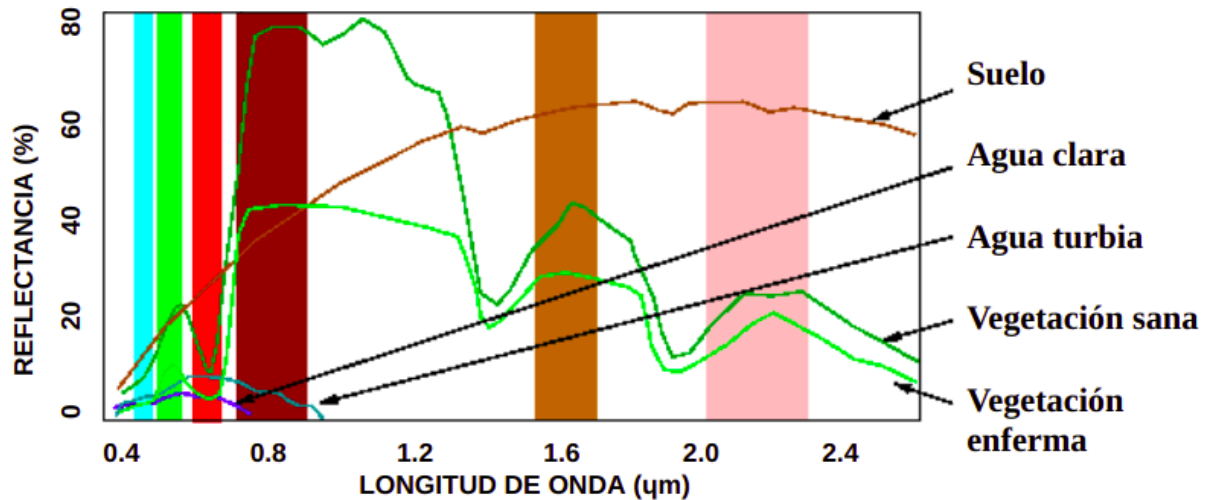


Figura 1.4: Signaturas espectrales de cinco cubiertas diferentes habituales en teledetección. Adaptada de [16].

La energía recibida por el sensor a lo largo del espectro, no solo depende de la reflectividad de la cubierta, sino también de otros factores externos como son las condiciones atmosféricas, el ángulo de iluminación solar y el ángulo de observación, las modificaciones en el relieve (la pendiente o la orientación), etc.

Si a esto añadimos que la reflectividad presenta también variaciones estacionales muy notables en algunos casos, podemos subrayar la complejidad que puede entrañar la caracterización de un tipo de cubierta a partir de sensores remotos.

1.2.5. Efecto de la atmósfera sobre la radiación electromagnética

Como se ha comentado anteriormente, en el tránsito de la radiación solar hacia el sensor, la atmósfera no se comporta como un cuerpo transparente, sino que impone en la misma un conjunto de modificaciones las cuales es importante tener en cuenta a la hora de utilizar cualquier sistema de teledetección. La atmósfera se compone de diversos gases, y algunos de los efectos más importantes que éstos producen en la radiación son la dispersión y la absorción atmosféricas, produciendo así, modificaciones en la intensidad y en la distribución espectral.

■ Absorción

En lo referente a la absorción atmosférica, la atmósfera se comporta como un filtro selectivo a distintas longitudes de onda, de tal forma que en algunas bandas del espectro elimina la práctica totalidad de la radiación (figura 1.5).

Los principales gases presentes en la atmósfera causantes de la absorción son fundamentalmente [13]:

- Ozono (O_3): Absorbe radiación ultravioleta.
- Oxígeno (O_2): Absorbe radiación ultravioleta por debajo de 100 nm
- Dióxido de Carbono (CO_2): Absorbe radiación en 13 - 17.5 μm
- Vapor de Agua: Absorbe radiación en 5.5 - 7 μm y por encima de 27 μm .




Figura 1.5: Espectro de radiación solar fuera de la atmósfera de la Tierra (área roja) y a nivel del mar para condiciones de cielo despejado (área naranja) [17].

La observación espacial se reduce por tanto, a determinadas bandas del espectro, conocidas como ventanas atmosféricas, en donde estos procesos son débiles y la transmisividad de la atmósfera es alta. Estas ventanas se centran principalmente en el ultravioleta, el visible, el infrarrojo reflejado y el infrarrojo térmico.

Los sensores utilizados actualmente en teledetección se diseñan especialmente para ajustarse a estas ventanas atmosféricas, de modo que si se desea observar la superficie terrestre, se ajustan a las zonas de alta transmisividad, mientras que si se desea monitorizar la atmósfera, los sectores espectrales más convenientes son, precisamente, aquellos donde la absorción atmosférica es alta.

■ **Dispersión**

La dispersión atmosférica, o “scattering”, aparece a causa de la difusión que las partículas en suspensión y las moléculas de la atmósfera producen sobre la radiación que interacciona con ellos. De forma general, la dispersión producida por las partículas, es menor a medida que aumenta la longitud de onda de la radiación. Pueden distinguirse varios tipos:

- **Dispersión “Mie”:** causada por las nubes y los aerosoles, se produce cuando las partículas y las moléculas presentes en la atmósfera tienen un diámetro comparable al tamaño de la longitud de onda de la radiación incidente, afectando por tanto a longitudes de onda largas.
- **Dispersión “Rayleigh”:** producida por las moléculas y partículas atmosféricas que tienen un diámetro menor que la longitud de onda de la radiación incidente, es más efectiva a longitudes de onda corta (extremo azul del espectro visible).
- **Dispersión “no selectiva”:** se produce cuando el tamaño de las partículas y moléculas atmosféricas es mucho más grande que la longitud de onda de la radiación. Los causantes de este tipo de dispersión suelen ser grandes partículas de polvo y pequeñas gotas de agua suspendidas en la atmósfera.

Los principales gases presentes en la atmósfera causantes de la dispersión son los aerosoles y el vapor de agua.

1.3. Características de la teledetección

Los sensores a bordo de los satélites producen las imágenes midiendo la radiancia procedente de la superficie terrestre y transformando la energía incidente en valores numéricos, denominados niveles digitales (ND), aprovechando el efecto fotoeléctrico, sobre sensores de silicio estructurados en píxeles. De este modo, el valor de cada píxel de la imagen es proporcional a la intensidad de radiancia procedente de la superficie terrestre.

Este procedimiento se lleva a cabo para cada una de las bandas espectrales en las que se mide la radiancia, generando así una imagen multispectral (figura 1.6) típica en teledetección. El resultado final es una matriz tridimensional en la que el valor del nivel digital de cada píxel está ubicado en una fila, una columna (correspondientes con las coordenadas geográficas) y una banda.




Figura 1.6: Imagen multispectral procesada para producir una composición de color RGB (rojo, verde y azul) [18].

1.3.1. Resolución de una imagen multispectral

La resolución en teledetección implica cuatro conceptos de suma importancia para el análisis de las imágenes: resolución espacial, resolución radiométrica, resolución espectral, resolución temporal [13].

Resolución espacial

Este concepto describe la capacidad del sistema para distinguir objetos en función de su tamaño. Designa el tamaño del objeto más pequeño que puede ser distinguido en una imagen.

Con mayor propiedad, deberíamos hablar del ángulo subtendido en el satélite por el píxel (IFOV, Instantaneous Field of View), que se define como la sección angular observada en un momento determinado, ya que el tamaño del píxel en una escena es variable incrementándose conforme nos alejamos.




Figura 1.7: Relación IFOV-tamaño de píxel.

No obstante, se suele utilizar normalmente como tamaño de píxel, d , la distancia sobre el terreno que corresponde a ese ángulo, teniendo en cuenta la altura de vuelo y la velocidad de exploración del sensor.

$$d = H \cdot IFOV \quad (1.2)$$

donde H es la distancia del sensor a la superficie terrestre.

Conviene destacar que son varios los factores que determinan la resolución espacial de un sensor remoto: distancia sensor-superficie terrestre, velocidad de exploración y número de detectores. La resolución espacial de los sensores de observación de la Tierra recoge un rango bastante amplio, pudiendo variar desde los 1 x 1m de satélites tales como Ikonos o OrbView 3, hasta los 5000 x 5000 m de los Meteosat.

Resolución radiométrica

Este concepto hace referencia a la sensibilidad del sensor e indica la capacidad de este para discriminar niveles o intensidades de radiancia. La radiancia detectada se presenta habitualmente en formato de imagen digital gracias a una conversión de los datos analógico -digital. Cuando se convierte a nivel digital, se necesita un formato binario (número de bits) para codificar. A mayor número de bits utilizados para almacenar el valor de reflectividad medido, mejor resolución radiométrica.

Algunos de los sensores más conocidos en la actualidad como son Landsat 8 o Sentinel-2 tienen una resolución radiométrica de 4096 niveles de intensidad (12 bits).

Resolución espectral

Indica el número y la anchura de las bandas espectrales que puede discriminar el sensor. De este modo, un sensor tendrá mejor resolución espectral cuanto mayor sea el número de bandas que proporcione y cuanto más específica sea la anchura de estas. Bandas muy amplias supone registrar un valor promedio que puede encubrir la diferenciación espectral entre las superficies a monitorizar.

La elección del número, la anchura y la localización (longitud de onda) de las bandas en las que mide el sensor (figura 1.8), se hace en función de su uso y de la superficies a monitorizar, ya que como se ha visto anteriormente, la firma espectral de cada superficie terrestre es diferente.

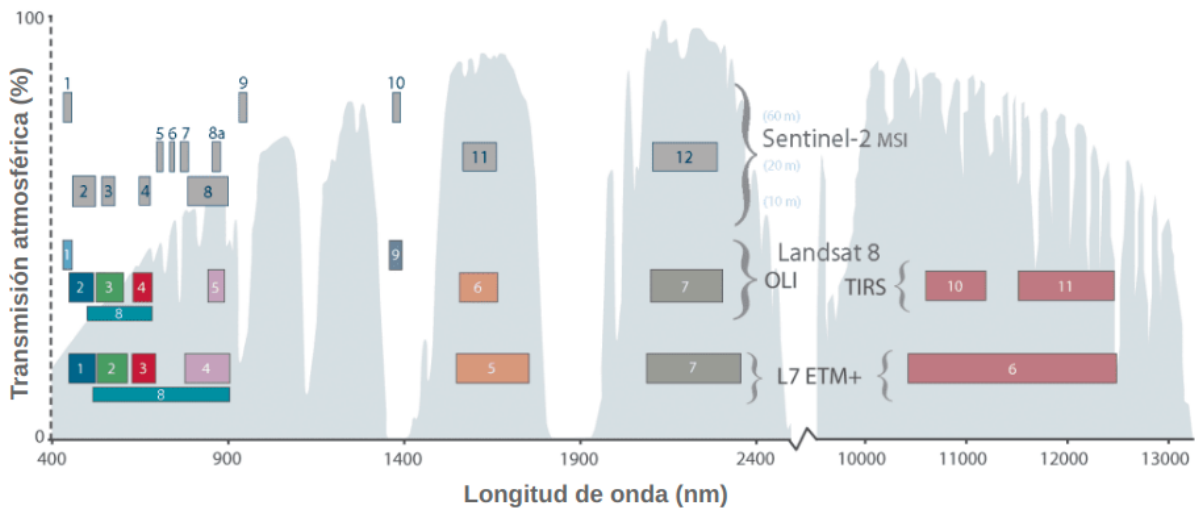


Figura 1.8: Comparación de la resolución espectral de los satélites Sentinel-2, Landsat 7 y Landsat 8 [19].

Resolución temporal

Se refiere a la periodicidad con la que se adquieren imágenes de la misma porción de la superficie terrestre. Es decir, mide el tiempo de revisita de una zona concreta de la Tierra. La resolución temporal está condicionada por el tipo de órbita, el ángulo de barrido y la velocidad del satélite.

1.3.2. Tipos de imagen de teledetección

El tipo de producto más común que suministran los satélites de teledetección es una imagen digital tipo raster, donde cada píxel tiene asignado uno o varios valores numéricos, ND, que hacen referencia a la energía media recibida para cada una de las bandas espectrales. Teniendo esto en cuenta, se pueden adquirir los siguientes tipos de imágenes [20]:

- **Imagen Multiespectral:**

Es la imagen más característica en teledetección. Esta imagen lleva asociados varios valores numéricos, tantos como bandas espectrales sea capaz de detectar el sensor, a cada uno de los píxeles de la imagen. Es el tipo de producto más útil ya que proporciona una mayor información espectral para identificar la firma espectral de las distintas superficies presentes en la imagen.

- **Imagen Pancromática:**

Una sola banda de gran anchura espectral que típicamente abarca parte del visible y el comienzo del infrarrojo, obteniendo como resultado una imagen que se representa en escala de grises. La principal utilidad de esta imagen es que se toma a una mayor resolución espacial que el resto de bandas multiespectrales para complemento de estas. Es importante para la detección de elementos pequeños no distinguibles en las imágenes multiespectrales.

- **Imagen Fusionada:**

Se obtiene mediante la técnica denominada pansharpening o fusión de imágenes (sección 4.1), y consiste en asignar a cada píxel de la imagen pancromática los valores procedentes de un algoritmo que combina la imagen pancromática con una combinación de bandas multiespectrales.

- **Imagen Estéreo:**

Se refiere a dos imágenes de una misma zona tomadas con ángulos de visión distintos. Algunos satélites tienen la capacidad de reorientar el sensor, lo que les permite tomar, en una o en sucesivas pasadas, este tipo de imágenes.

1.4. Correcciones de la imagen

Como ya se ha comentado anteriormente, cuando el sensor del satélite detecta la radiancia procedente de la superficie terrestre, la convierte mediante un proceso digital-analógico a un valor numérico, de forma que, cada píxel de la imagen viene definido por un valor numérico entero, proporcional a la radiancia recibida por el sensor, para una determinada parcela de la superficie terrestre y una determinada banda del espectro electromagnético.

Este valor numérico se denomina en teledetección nivel digital (ND), y puede interpretarse fácilmente como una intensidad visual (o como un nivel de gris), que hace que los datos queden organizados como una matriz tridimensional en la que el valor ND de cada píxel está ubicado en una fila y en una columna, correspondientes con las coordenadas geográficas, y una banda espectral. La orientación aproximada Norte-Sur se expresa a través de las filas de la matriz, mientras que las columnas indican la disposición Oeste-Este. El origen de coordenadas se sitúa en la esquina inferior-izquierda.

El análisis digital de las imágenes de satélite empieza, por tanto, con esta matriz numérica tridimensional, pero cualquier imagen adquirida por un sensor remoto, presenta una serie de alteraciones radiométricas y geométricas debidas a los siguientes factores [13]:

- **Alteraciones originadas por la plataforma:** Pequeñas variaciones en la altitud de la órbita, en la velocidad o en la orientación.
- **Distorsiones provocadas por la rotación terrestre:** En el lapso de tiempo en que transcurren las medidas, la tierra se ha desplazado sensiblemente debido a la rotación terrestre, lo que causa pequeñas distorsiones en la orientación.
- **Distorsiones provocadas por el sensor:** La falta de calibración entre detectores o alteraciones en el movimiento de barrido, pueden provocar defectos en la geometría de la adquisición o la pérdida de píxeles en la imagen.
- **Distorsiones provocadas por la atmósfera:** Los componentes de la atmósfera causan una modificación de la radiancia original proveniente de la Tierra.

Los procesos de corrección aplicados a las imágenes tienen como finalidad restaurar la imagen restableciendo, en la medida de lo posible, las condiciones originales de la toma. Esto implica el desarrollo de dos tipos de correcciones: unas de índole geométrica y otras de carácter radiométrico.

1.4.1. Correcciones radiométricas

Incluyen las técnicas que pretenden restablecer los niveles digitales que originalmente corresponden a la imagen, depurando cualquier anomalía en su registro, bien sea por defectos en el sensor, o por las condiciones atmosféricas. Dentro de estas técnicas se incluyen [21]:

- **Restauración de píxeles perdidos.**

Un mal funcionamiento del sensor o de la antena receptora puede llevar a que en la imagen aparezcan algunas líneas o píxeles perdidos (figura 1.9).




Figura 1.9: Ejemplo de una imagen en la que aparecen líneas de píxeles perdidos [22].

Para estimar el nivel digital de los píxeles perdidos, se utiliza el valor de los píxeles vecinos de la misma banda, pero puesto que estos valores no son muy fiables ya que se han tomado con el mismo sensor que ha fallado en el otro píxeles, y gracias a la alta correlación entre bandas, se utiliza también el valor de los píxeles vecinos de otras bandas para mejorar la estimación.

1.4.2. Corrección del bandeo de la imagen

Este fenómeno se debe a una mala calibración entre detectores, y el resultado es la aparición periódica de una franja más clara u oscura que las demás (figura 1.10).




Figura 1.10: Ejemplo de una imagen multispectral con errores de bandeo [23].

Para corregir el bandeo de las imágenes se asume que los histogramas obtenidos por cada uno de los detectores son iguales entre sí, e iguales al histograma global de la imagen que se toma como referencia, lo que permite calcular los coeficientes de correlación entre detectores a_k y b_k .

$$b_k = \frac{s}{s_k} \quad (1.3)$$

$$a_k = m - b_k m_k$$

donde m y s son la media y la desviación típica del conjunto de píxeles de la imagen, y m_k y s_k la media y la desviación típica de los píxeles obtenidos por el detector k . Con estos coeficientes podemos estimar los valores de ND como:

$$(ND_{CORR})_{i,j} = a_k + b_k (ND)_{i,j} \quad (1.4)$$

1.4.3. Correcciones geométricas o georreferenciación

Las correcciones geométricas o georreferenciación no pretenden modificar los valores ND de la imagen, sino reconstruir su geometría, adaptándola a una determinada proyección cartográfica y a su sistema de coordenadas asociado.

Como se ha comentado, el satélite no proporciona imágenes georreferenciadas, sino que cada píxel se ubica en un sistema de coordenadas de tipo fila-columna. El proceso de georreferenciación consiste, por tanto, en dar a cada píxel una localización en un sistema de coordenadas estándar (UTM, Lambert, coordenadas geográficas) para poder, de este modo, combinar la imagen de satélite con Sistemas de Información Geográfica (SIG).

En caso de que la imagen no hubiese sufrido ningún tipo de distorsión, el procedimiento sería bastante sencillo, y bastaría con aplicar un par de ecuaciones para asignar a cada punto de la imagen sus coordenadas reales (X e Y en UTM).

$$\begin{aligned} X &= f_1(f, c) \\ Y &= f_2(f, c) \end{aligned} \tag{1.5}$$

es decir, las coordenadas x e y de la imagen georreferenciada, son función de las coordenadas f, c (fila, columna) de la imagen original.

Sin embargo, existen dos enfoques diferentes para hacer la georreferenciación, y la forma y los parámetros de estas ecuaciones pueden variar en función de cuál se escoja. Los dos métodos son:

- **Corrección orbital:** Mediante información detallada de las características de órbita del satélite y del sensor, modeliza las fuentes de error y su influencia, corrigiendo los errores sistemáticos, como son los derivados de la rotación terrestre o de la inclinación orbital. Este tipo de correcciones es idóneo para sensores de baja resolución espacial, ya que necesita poca información del terreno.
- El segundo es un enfoque empírico, que parte de un cartografía básica y modeliza la distribución de errores en la imagen utilizando **puntos de control**.

En ambos casos, la corrección se realiza en tres fases:

1. **Localización de puntos de control:** El primer paso es buscar una serie de puntos de control a lo largo de toda la imagen y averiguar las coordenadas de esos puntos en los dos sistemas de coordenadas. Las funciones que permiten transformar las coordenadas de la imagen en coordenadas reales, precisan de puntos de control para poder ejecutarse. La calidad del ajuste dependerá de esos puntos de control, por lo que un adecuado número de puntos de control y una distribución homogénea de estos por toda la imagen, son factores importantes a tener en cuenta para evitar que las distorsiones locales adquieran demasiado peso en las ecuaciones. Obviamente, el número de puntos deberá ser mayor cuanto más grande sea la imagen, y cuanto más abrupto sea el relieve.
2. **Cálculo de las funciones de transformación:** El segundo paso es determinar el tipo de transformación más adecuado, y con ello las funciones para esta transformación, en función del tipo de datos de partida y del número y calidad de los puntos de control.

La corrección digital de la geometría de las imágenes se realiza mediante funciones de regresión que ponen en relación las coordenadas de la imagen y las coordenadas reales. Los algoritmos más habituales son transformaciones lineales o cuadráticas.

Los coeficientes de las funciones se calculan a partir de los puntos de control, y se calcula el error cuadrático medio (RMSE), entre la estimación y las coordenadas reales, para determinar si es necesario ampliar el número de puntos de control utilizados.

3. **Georreferenciación de los ND originales:** En el último paso se aplican las ecuaciones ya calculadas en el paso anterior a todas las coordenadas iniciales de la imagen original para obtener así sus nuevos valores en el sistema de referencia final. Una vez calculadas, cada píxel de la capa transformada debería corresponderse idealmente con un solo píxel en la imagen original. Sin embargo, lo habitual es que el píxel de la nueva imagen se sitúe entre varios píxeles de la original, pudiendo incluso variar el tamaño de estos.

El trasvase de valores de la capa original a la transformada se puede abordar por tres métodos diferentes dependiendo de la complejidad de la transformación realizada y del tipo de dato.

- **Método del vecino más próximo:** Este método consiste en situar en cada píxel de la imagen corregida el valor del píxel más cercano en la imagen original. Es la solución más rápida, pero su principal inconveniente es que introduce distorsiones lineales de la imagen.
- **Interpolación bilineal:** Se promedian los valores de los cuatro píxeles más cercanos de la capa original. El valor promedio obtenido se pondera después según la distancia del píxel original al corregido, de este modo tienen una mayor influencia aquellos píxeles más cercanos en la capa inicial.
- **Convolución cúbica:** Se consideran los valores de los 16 píxeles más próximos.

1.4.4. Correcciones atmosféricas

Como ya se ha comentado anteriormente, la radiación electromagnética se ve notablemente afectada por los efectos de absorción y dispersión producidos por los componentes de la atmósfera. La presencia de aerosoles y vapor de agua produce que la radiancia final detectada por el sensor no corresponda únicamente a la superficie terrestre, sino que resulta por un lado reducida por la absorción atmosférica y por otro, incrementada por la radiancia introducida por la dispersión. Este fenómeno se puede expresar mediante la ecuación:

$$L_{sensor,\lambda} = L_{suelo,\lambda} \cdot \tau_{\lambda,o} + L_{atmósfera,\lambda} \quad (1.6)$$

donde $L_{sensor,\lambda}$ es la radiancia recibida por el sensor para cada longitud de onda, $L_{suelo,\lambda}$ es la radiancia original reflectada por la superficie terrestre, $L_{atmósfera,\lambda}$ radiancia introducida por la atmósfera y $\tau_{\lambda,o}$ es la transmisividad de la atmósfera .

Es decir, la radiación que llega al sensor es la procedente del suelo multiplicada por la transmisividad de la atmósfera en camino ascendente, más la radiancia aportada por la dispersión atmosférica.

La principal complicación que implica el cálculo de las correcciones atmosféricas es su carácter heterogéneo, tanto en el espacio como en el tiempo. La dispersión producida por la atmósfera no es constante, sino que varía en función de la concentración de aerosoles o vapor de agua en la atmósfera. Además, el efecto también varía en función de la longitud de onda y en consecuencia, entre diferentes medidas espectrales tomadas con el mismo sensor. Estas correcciones se van a basar, por tanto, en modelos físicos más complejos que los modelos estadísticos utilizados en otras correcciones, pero pese a las dificultades que pueda implicar esta corrección, es preciso realizarla, ya que su influencia en los datos es importante.

El primer paso para aplicar las correcciones atmosféricas, es dar a las medidas tomadas por el sensor un sentido físico, transformando los ND originales de las imágenes, a valores de reflectancia.

Conversión de los ND a valores de reflectancia

- Conversión de ND a radiancia.

Radiancia es el “*Flujo de energía por ángulo sólido que abandona una unidad de área de una superficie en una dirección dada*” [15]. Como ya sabemos, la radiancia es lo que detecta el sensor y los ND son traducciones digitales de esta radiancia. Es por ello, que se puede volver a recuperar dicha radiancia fácilmente a partir de los coeficientes de calibración del sensor.

$$L_{sensor,\lambda} = a_{0,\lambda} + a_{1,\lambda} \cdot ND_{\lambda} \quad (1.7)$$

donde L_{sensor} , corresponde a la radiancia espectral recibida por el sensor para cada banda, en W/m^2 y a_0 , y a_1 , son los coeficientes de calibración del sensor para la banda.

Estos coeficientes de calibración para cada banda son proporcionados con cada producto del satélite, y se pueden encontrar en el archivo de metadatos.

- Reflectancia en el techo de la Atmósfera (TOA)

El siguiente paso es convertir las imágenes con valores de radiancia a valores de Reflectancia en el Techo de la Atmósfera (Top of the Atmosphere, TOA), la cual combina la reflectancia de la superficie y la reflectancia atmosférica, para reducir la variabilidad íter-imagen a través de una normalización de la irradiancia solar. Esta reflectancia TOA (ρ_{TOA}), el ratio entre la energía reflejada y la energía total incidente [24], puede ser calculada como:

$$\rho_{TOA,\lambda} = \frac{L_{sensor,\lambda} \cdot d_{ES}^2 \cdot \pi}{ESUN_{\lambda} \cdot \cos(\theta_{incidente})} \quad (1.8)$$

donde $L_{sensor,\lambda}$ es la radiancia espectral en el sensor, d_{ES} la distancia Tierra-Sol en unidades astronómicas, $ESUN_{\lambda}$ (Effective Exo-Atmospheric Solar Irradiance) la irradiancia media solar exoatmosférica y $\theta_{incidente}$ es el ángulo cenital de la radiación incidente en grados.

- Reflectancia de la Superficie

Si incorporamos ahora los efectos atmosféricos, e introducimos los distintos coeficientes de los que depende la ecuación 1.8, la reflectancia de la superficie (ρ) puede representarse mediante [25]:

$$\rho_{\lambda} = \frac{(L_{sensor,\lambda} - L_{atmósfera,\lambda}) \cdot d_{ES}^2 \cdot \pi}{\tau_{\lambda,observación}(E_{atmósfera,\lambda} \cdot \cos\theta_{incidente} \cdot \tau_{\lambda,incidente} + E_{difusa,\lambda})} \quad (1.9)$$

donde $L_{atmósfera,\lambda}$ es la radiancia aportada por la dispersión atmosférica, $\tau_{\lambda,observación}$ la transmitancia de la atmósfera en la dirección de visión (transmisividad observada), $E_{atmósfera,\lambda}$ la irradiancia en lo alto de la atmósfera, $\tau_{\lambda,incidente}$ la transmitancia atmosférica en la dirección de iluminación (transmisividad incidente) y $E_{difusa,\lambda}$ la irradiancia difusa descendiente.

Estos coeficientes pueden ser medidos o estimados dependiendo del método utilizado para aplicar dichas correcciones atmosféricas. La deducción completa de esta ecuación, así como el análisis de cada coeficiente y los métodos para su medición o estimación se explican con detalle más adelante, en el capítulo 4, Pre-procesado de las imágenes, en el apartado 4.2 (Correcciones atmosféricas).

1.5. Plataformas espaciales de Teledetección

Se calcula que actualmente hay más de 900 satélites artificiales operativos orbitando alrededor de la Tierra, de los que, aproximadamente unos 120 son utilizados para teledetección. Todos los años son varios los satélites de este tipo que se lanzan al espacio y otros tantos los que dejan de estar operativos, por lo que su número varía permanentemente. En el futuro, el número de satélites de teledetección en órbita continuará aumentado, así como las constelaciones de satélites con sensores cada vez más perfeccionados para conseguir un mejor conocimiento de los fenómenos a observar.

En este apartado únicamente nos hemos centrado en explicar los satélites de teledetección que se han utilizado en este estudio.

1.5.1. Misión LANDSAT

El programa Landsat es una serie de misiones de observación de la Tierra por satélite administrada conjuntamente por la NASA y el Servicio Geológico de EE.UU (USGS, United States Geological Survey). Este programa nació con el objetivo de aportar datos a gran escala a los estudios de las cubiertas terrestres, pero actualmente se emplea también para estudios de hidrología, recursos costeros, usos del suelo, aplicaciones agrícolas y forestales y monitorización medioambiental.

En 1972, con el lanzamiento de ERTS-1 (Earth Resources Technology Satellite, más tarde renombrado Landsat 1), comenzó el programa Landsat, la serie más larga existente hasta la fecha de imágenes satelitales comerciales de observación terrestre, y mediante el cual se ha podido hacer un seguimiento de los grandes cambios que se han producido en la superficie de nuestro planeta [6].

En la actualidad el programa se encuentra en su octava versión denominada: “Landsat Data Continuity Mission” (LDCM), el cual se puso en marcha el 11 de febrero de 2013. El octavo satélite de observación de la serie Landsat, ahora renombrado como Landsat 8, es uno de los satélites que se han utilizado en este trabajo.

Landsat 8

El satélite Landsat 8 orbita la Tierra en una órbita casi polar y sincrónica al sol, a una altitud de 705 km e inclinada a 98.2 grados, y da una vuelta alrededor de la Tierra cada 99 minutos. El satélite tiene un ciclo de repetición de 16 días y adquiere alrededor de 740 escenas por día, con una superposición de franjas (o solapamiento) que varía del 7 por ciento en el ecuador a un máximo de aproximadamente el 85 por ciento en latitudes extremas . El tamaño de la escena es de 185 km x 180 km [24].

Los dos instrumentos a bordo del Landsat 8, Operational Land Imager(OLI) y el sensor térmico infrarrojo (Thermal Infrared Sensor, TIRS) representan avances evolutivos en la tecnología de sensores remotos y en su rendimiento. OLI y TIRS miden la superficie terrestre en el visible, infrarrojo cercano, infrarrojo de onda corta, e infrarrojo térmico con una resolución moderada, entre 15 y 100 metros, dependiendo de la longitud de onda espectral. La distribución de la energía observada en estas longitudes de onda revela información sobre la reflexión y emisión de superficies.

– Sensor OLI

Las bandas espectrales del sensor Operational Land Imager(OLI) (figura 1.11), proporcionan una mejora respecto a los instrumentos de las misiones Landsat anteriores, debido a la incorporación de dos nuevas bandas espectrales; un canal profundo en el azul visible (banda 1), diseñado específicamente para los recursos hídricos e investigación en zonas costeras, y un nuevo canal infrarrojo (banda 9) para la detección de nubes cirrus, operando por tanto en nueve longitudes de onda en el rango de 0.433 - 2.300 μm . Adicionalmente se incluye también con cada producto de datos generado una nueva banda de control de calidad, lo que proporciona información más detallada sobre la presencia de nubes, agua y nieve.




Figura 1.11: Instrumento OLI del satélite Landsat 8 [24].

A diferencia de los primeros satélites Landsat, equipados con sensores “whiskbroom” que empleaban espejos oscilantes para barrer el campo de visión a lo largo del ancho de banda espectral y transmitir la luz a los detectores, el sensor OLI utiliza un sensor del tipo “pushbroom” compuesto por una serie de largas baterías de detectores, con más de 7.000 detectores por banda espectral, alineados en su plano focal en su respectivo ancho de banda. Este diseño hace que el instrumento sea más sensible y proporciona una mejor información de la superficie terrestre con menos partes móviles.

– Sensor TIRS

Por otra parte, el sensor térmico Thermal Infrared Sensor (TIRS), recoge dos bandas espectrales y su objetivo principal es obtener las características de temperatura de la superficie y estudiar el proceso de transferencia de calor y humedad en el ámbito de la agricultura, la gestión del agua, etc (figura 1.12).




Figura 1.12: Instrumento TIRS del satélite Landsat 8 [24].

Al igual que OLI, TIRS es un sensor de barrido que utiliza un plano focal con largas series de detectores fotosensibles. Estos foto-detectores infrarrojos de pozo cuántico (Quantum well Infrared Photodetector, QWIP) miden la energía infrarroja térmica de onda larga (Thermal Infrared, TIR) emitida por la superficie de la Tierra, cuya intensidad es función de la temperatura de la superficie. Según los principios de la mecánica cuántica, los chips semiconductores de arseniuro de galio atrapan electrones en un estado de energía “pozo” hasta que los electrones pasan a un estado superior por la luz infrarroja térmica de cierta longitud de onda. Los electrones elevados crean una señal eléctrica que puede leerse, grabarse, traducirse a unidades físicas y usarse para crear una imagen digital.

Los foto-detectores infrarrojos de pozo cuántico del detector TIRS son sensibles a dos bandas de longitud de onda infrarroja térmica, lo que permite la separación de la temperatura de la superficie de la Tierra y de la atmósfera.

– Descripción de Productos Landsat 8

Las imágenes se componen por tanto de ocho bandas espectrales con una resolución espacial de 30 metros, bandas 1 a 7 y 9 y dos bandas térmicas 10 y 11 útiles para proporcionar temperaturas de la superficie más precisa con una resolución de 100 metros. Se dispone también de una banda pancromática (banda 8) de resolución espacial 15 metros (figura 1.8 y tabla 1.1).

	Bandas	Longitud de onda (μm)	Resolución (m)
Landsat 8	Banda 1 - Aerosol costero	0.43 - 0.45	30
	Banda 2 - Azul	0.45 - 0.51	30
	Banda 3 - Verde	0.53 - 0.59	30
	Banda 4 - Rojo	0.64 - 0.67	30
	Banda 5 - NIR	0.85 - 0.88	30
	Banda 6 - SWIR 1	1.57 - 1.65	30
	Banda 7 - SWIR 2	2.11 - 2.29	30
	Banda 8 - Pancromático	0.50 - 0.68	15
	Banda 9 - Cirrus	1.36 - 1.38	30
	*Banda 10 - TIRS 1	10.60 - 11.19	100
	*Banda 11 - TIRS 2	11.50 - 12.51	100

Tabla 1.1: Distribución espectral de los sensores OLI y TIRS del satélite Landsat 8. *Las bandas TIRS se adquieren a una resolución de 100 metros, pero se remuestrean a 30 metros antes de su publicación para que coincida con las bandas multispectrales de OLI.

Los productos de datos estándar de Nivel 1 se encuentran en formato de niveles digitales enteros, con una resolución radiométrica de 16 bits, los cuales se pueden reescalar a la reflectancia de la parte superior de la atmósfera (TOA) utilizando los coeficientes de reescalado radiométrico provistos en el archivo de metadatos del producto (archivo MTL). La relación señal/ruido permite una caracterización mejorada del estado y la condición de la cobertura del suelo.

A continuación se detallan las descripciones de los tipos de producto de Nivel 1 proporcionados por el USGS y utilizados en este proyecto:

- Nivel 1 Terrain (L1T): Consisten en datos de nivel L1R a los que se les han aplicado correcciones geométricas mediante puntos de control terrestre (Ground Control Points, GCP) o información de posición integrada a bordo del satélite. Se entrega, por tanto, una imagen con proyección cartográfica, referenciada a WGS84, G873, o a su versión actual. A estos datos también se les ha aplicado una corrección topográfica para corregir el desplazamiento del terreno debido al relieve.

Procesamiento	Nivel 1 T-Corrección geométrica
Tamaño de pixel	Bandas OLI multiespectrales 1-7,9: 30 <i>m</i> Bandas OLI pancromática 8: 15 <i>m</i> Bandas TIRS 10 y 11: tomadas en 100 <i>m</i> , remuestreadas a 30m para que coincida con las bandas multiespectrales
Características	Formato de datos GeoTIFF Remuestreo por convolución cubica (CC) Norte arriba (MAP) de orientación Proyección: UTM Datum al Sistema Geodesico Mundial (WGS) 84 12 metros de error circular, 90% de confianza exactitud global para OLI 41 metros de error circular, 90% de confianza exactitud global para TIRS Valores de pixel en 16 bits
Tamaño archivo	Aproximadamente 1 GB

Tabla 1.2: Especificaciones de productos Landsat 8 a Nivel 1. [24].

Por lo tanto, los datos de Nivel 1 disponibles para los usuarios son una imagen corregida radiométricamente y geoméricamente. El resultado es un producto rectificado geoméricamente libre de distorsiones relacionadas con el sensor, el satélite o la Tierra. La imagen también se corrige radiométricamente para eliminar las diferencias relativas del detector, el sesgo de corriente oscura y algunos artefactos. La imagen de Nivel 1 se presenta en unidades de niveles digitales, que se pueden reescalar fácilmente a radiancia espectral o reflectancia en el techo de la atmósfera.

1.5.2. Programa Copernicus y misiones Sentinel

El programa Copernicus es una iniciativa liderada por la Comisión Europea en colaboración con la Agencia Espacial Europea (ESA). Este programa tiene como misión construir un sistema autónomo de observación de la Tierra en base a la observación espacial utilizando una red de satélites, la observación in-situ mediante redes de estaciones de medida en tierra y medios aéreos, y la generación de servicios de información.

Las familias de satélites utilizadas por el programa Copernicus se denominan las misiones Sentinel. Cada una de estas misiones cuenta una constelación de dos satélites que permite cumplir los requisitos de resolución temporal y ofrecer un robusto conjunto de datos a los servicios del programa Copérnico. Además, estas misiones están equipadas con las tecnologías más avanzadas para la observación de la Tierra, como los instrumentos radar o multiespectrales que permiten monitorizar cualquier cambio en el terreno, en los océanos o en la atmósfera.

Dentro de la familia de satélites Sentinel, el Sentinel-2 está destinado a proveer imágenes ópticas de alta resolución para servicios terrestres, y es la misión que se ha utilizado en este trabajo.

Sentinel-2

Dos satélites Sentinel-2 idénticos operan simultáneamente, en fase a 180° entre sí, en una órbita polar, heliosíncrona, a una altitud de 786 km, con cobertura sistemática de la tierra y de áreas costeras entre 84°N y 56°S . Su misión es la monitorización de la tierra para proporcionar imágenes de vegetación, suelo y cubierta de agua, vías navegables y zonas costeras y está diseñada para ofrecer una alta frecuencia de revisión de 5 días en el ecuador [26].

Equipados con un sensor multiespectral, el MultiSpectral Instrument (MSI), ambos satélites son capaces de obtener información espectral de la superficie de la tierra con resoluciones espaciales que van desde 10 a 60 m y espectrales que van desde 442 nm hasta 2185 nm.

Banda	S2A		S2B		Resolución espacial (m)
	λ (nm)	Ancho de banda (nm)	λ (nm)	Ancho de banda (nm)	
B 1 - Aerosol	443.9	27	442.3	45	60
B 2 - Azul	496.6	98	492.1	98	10
B 3 - Verde	560.0	45	559	46	10
B 4 - Rojo	664.5	38	665	39	10
B 5 - NIR	703.9	19	703.8	20	20
B 6 - NIR	740.2	18	739.1	18	20
B 7 - NIR	782.5	28	779.7	28	20
B 8 - NIR	835.1	145	833	133	10
B 8A - NIR	864.8	33	864	32	20
B 9 - Vapor de agua	945.0	26	943.2	27	60
B 10 - Cirrus	1373.5	75	1376.9	76	60
B 11 - SWIR	1613.7	143	1610.4	141	20
B 12 - SWIR	2202.4	242	2185.7	238	20

Tabla 1.3: Distribución espectral de las bandas del sensor MSI de Sentinel-2. [26]

La resolución radiométrica del instrumento MSI es de 12 bits, lo que permite que la imagen se obtenga en un rango de valores de intensidad de luz potencial de 0 a 4095.

– Sensor MSI

El MSI (figura 1.13) es un sensor pasivo que mide la radiación reflejada de la Tierra en 13 bandas espectrales que van desde el visible hasta el infrarrojo de onda corta (tabla 1.3). El haz de luz entrante pasa por un divisor de haz dicróico VNIR/SWIR (Visible and Near-InfraRed y Shortwave Infrared) y se enfoca en dos conjuntos distintos de 12 detectores montados en cada plano focal que cubren los canales VNIR y SWIR respectivamente.




Figura 1.13: Sensor MSI del satélite Sentinel-2. [26]

Los 12 detectores en cada plano focal están en una configuración escalonada para cubrir todo el campo de visión. La separación espectral en las diversas bandas se proporciona mediante filtros de banda montados en la parte superior de los detectores.

– Descripción de Productos

Nivel 1C: El producto Level-1C está compuesto por mosaicos de 100 km² (ortoimágenes en proyección UTM / WGS84). El producto de nivel 1C resulta del uso de un modelo digital de elevación (Digital Elevation Model, DEM) para proyectar la imagen en coordenadas cartográficas. Las mediciones radiométricas por píxel se proporcionan en reflectancias TOA, con todos los parámetros para transformarlas en radiación. Los productos de nivel 1C se vuelven a muestrear con una distancia de muestreo de terreno (Ground Sampling Distance, GSD) constante de 10, 20 y 60 m, dependiendo de la resolución nativa de las diferentes bandas espectrales. En los productos de nivel 1C, las coordenadas de píxel se refieren a la esquina superior izquierda del píxel. Los productos de nivel 1C también incluirán datos de tierra/agua, máscaras de nubes y ECMWF (columna total de ozono, columna total de vapor de agua y presión media del nivel del mar).

Nivel 2A: El producto Level-2A proporciona imágenes de reflectancia en el fondo de la atmósfera (Bottom-of-Atmosphere, BOA) derivadas de los productos Level-1C asociados. Por lo tanto, cada producto de Nivel 2A también se compone de mosaicos de 100 km² en geometría cartográfica (proyección UTM / WGS84). Los productos de nivel 2A se generan sistemáticamente en el segmento de tierra. El usuario también puede realizar la generación de nivel 2A a través de la caja de herramientas Sentinel-2 utilizando como entrada el producto de nivel 1C asociado.

Para el desarrollo de esta tesis se ha utilizado en ambos casos productos de Nivel 1, una imagen corregida radiométricamente y geoméricamente, Nivel 1 Terrain (L1T) para Landsat 8 y Nivel 1C para Sentinel-2.

Capítulo 2

Masas de Agua Continentales y Teledetección

Según la Directiva Marco del Agua (DMA), Directiva 2000/60/CE del Parlamento Europeo y del Consejo por la que se establece un marco comunitario de actuación en el ámbito de la política de aguas, se entiende por “*aguas continentales*”: “*todas las aguas quietas o corrientes en la superficie del suelo y todas las aguas subterráneas situadas hacia tierra desde la línea que sirve de base para medir la anchura de las aguas territoriales*”. Así mismo, dicha directiva DMA define el “*buen estado de las aguas superficiales*” como: “*el estado alcanzado por una masa de agua superficial cuando tanto su estado ecológico como su estado químico son, al menos, buenos*” [27].

En Europa, más de la mitad de los lagos y embalses registrados en la base de datos WISE (The Water Information System for Europe) de la Agencia Ambiental Europea, un total de 2.227, están en riesgo de contaminación. En España, un país con unos 1200 embalses, más del 50 % están afectados por la eutrofización y casi el 25 % presentan dominancia de cianobacterias según datos de 2017 [28].

La eutrofización, el aporte excesivo de nutrientes, principalmente fósforo (P) y nitrógeno (N), en un ecosistema acuático, que produce una proliferación descontrolada de algas fitoplanctónicas o las proliferaciones masivas de cianobacterias potencialmente tóxicas, es una de las principales formas de contaminación del medio acuático en lagos, balsas, ríos, embalses, etc. (figura 2.1), y compromete el buen estado ecológico de las masas de agua continentales, y los usos del agua. En ocasiones puede incluso suponer un riesgo sanitario.



Figura 2.1: Imagen del embalse de Cedillo, en la cuenca hidrográfica del río Tajo, en Cáceres, es estado hipereutrófico, el 11 de abril de 2019 [29].

El efecto más inmediato de la eutrofización es un incremento de la producción primaria del fitoplancton y de los macrófitos acuáticos, pero también puede acarrear cambios en el flujo de energía de las redes tróficas acuáticas y amplios efectos ecosistémicos [30].

Los organismos del fitoplancton que más frecuentemente se asocian con la eutrofización severa de las aguas continentales, las cianobacterias, pueden formar proliferaciones de muy alta densidad celular y causar daños severos al ecosistema y grandes pérdidas económicas. Algunos de los efectos de estas floraciones de algas nocivas (FAN) o cHAB, (Cyanobacterial Harmful Algae Blooms) son la pérdida de transparencia del agua, acusadas fluctuaciones de los niveles de oxígeno y del pH, olores y sabores desagradables y liberación de toxinas al medio acuático, lo que puede ocasionar la muerte de especies acuáticas, pero también de ganado e incluso en ocasiones del ser humano [31].

Aunque se tiene conocimiento de proliferaciones de cianobacterias tóxicas en cuerpos de agua dulce y salada desde hace al menos 2.000 años [32], este es un problema ambiental vigente y con una tendencia negativa debido a su relación con el cambio climático y con las actividades humanas.

El “Programa Internacional Cooperación sobre la Eutrofización”, el estudio mundial más completo hasta ahora realizado sobre la eutrofización [33], desarrollado en la década de 1970 por la Organización de Cooperación y Desarrollo Económicos para la Supervisión de Aguas Interiores (OCDE, 1982), otorga valores límites de concentración de nutrientes (fósforo y nitrógeno), por ser el primer indicador de eutrofización, y también valores límites de concentración de clorofila y turbidez, estimada a partir de la profundidad del Secchi, para los diferentes niveles. El disco de Secchi es un instrumento de medición de la transparencia del agua, y por lo tanto de la turbidez, en masas de agua tales como ríos, lagos, etc. Esta medida resulta clave para evaluar el estado ecológico de una masa de agua, y define de forma práctica la capa fótica del embalse, es decir, la zona en la que penetra la luz y en la que es posible, por tanto, la producción primaria de las microalgas.

La secuencia de estados tróficos propuesta por la OCDE en este estudio (tabla 2.1), que va desde oligotróficos (con un bajo nivel de nutrientes) hasta hipertróficos (con gran abundancia de nutrientes), se presenta a continuación.

Nivel Trófico	Concentración de fósforo (mg/m^3)	Concentración de Clorofila ($\mu g/l$)		Transparencia del Disco de Secchi (m)	
		Media	Máxima	Media	Máxima
Ultraoligotrófico	< 4.0	< 1.0	< 2.5	> 12	> 6.0
Oligotrófico	< 10.0	< 2.5	< 8.0	> 6.0	> 3.0
Mesotrófico	10 - 35	2.5 - 8.0	8.0 - 25	6.0 - 3.0	3.0 - 1.7
Eutrófico	35 - 100	8.0 - 25	25 - 75	3.0 - 1.5	1.5 - 0.7
Hipereutrófico	> 100	> 25	> 75	< 1.5	< 0.7

Tabla 2.1: Valores límites de la OCDE para un sistema completo de clasificación trófica. Adaptado de [33].

Además, en función del nivel trófico de la masa agua, se determina el tipo de uso o usos específicos para los que puede emplearse este recurso, y el establecimiento de medidas de control de la eutrofización. En España, según el Centro de Estudios y Experimentación de Obras Públicas (CEDEX), esos grados son (tabla 2.2) [34].

Uso deseado	Estado trófico requerido	Estado trófico aceptado
Producción de agua potable	Oligotrófico	Mesotrófico
Baño/Natación	Mesotrófico	Ligeramente eutrófico
Cultivo de salmónidos	Oligotrófico	Mesotrófico
Cultivo de ciprínidos	-	Eutrófico
Deportes acuáticos sin baño	Mesotrófico	Eutrófico
Regadío	-	Hipereutrófico
Producción de Energía	-	Hipereutrófico

Tabla 2.2: Usos del agua aceptados en función del estado trófico.

En la actualidad, el monitorizar de las aguas continentales se realiza normalmente, mediante técnicas de muestreo in-situ y el análisis sistemático de componentes en el laboratorio. Sin embargo, la adopción de medidas correctoras de la eutrofización es difícil de optimizar mediante estos métodos de monitorización debido a la gran complejidad de los ecosistemas acuáticos.

Este proyecto, y la teledetección en general, aportan una alternativa real a la monitorización in-situ con el fin de avanzar hacia una gestión adaptativa del problema. Las técnicas de teledetección posibilitan un mejor y más exacto seguimiento espacial dadas las resoluciones con las que trabajan actualmente los sensores a bordo de plataformas espaciales, y a la posibilidad de monitorizar toda la superficie de la masa de agua con una sola imagen.

El trabajo a realizar para monitorizar las masas de agua continentales mediante teledetección se puede dividir en dos partes bien diferenciadas:

- I. Por un lado, el primer paso consiste en identificar y mapear de forma fiable las masas de agua continentales, diferenciándolas de cualquier otra superficie que se puedan encontrar en la Tierra ya sea bosque o nieve. La parte más compleja de este proceso son los píxeles frontera entre agua y tierra, donde la radiación perteneciente a los píxeles tierra puede introducir ruido en las medidas.
- II. La segunda parte del proceso consiste en la monitorización de la calidad del agua mediante la estimación de varios parámetros fundamentales tales como la temperatura, la turbidez o la concentración de clorofila. Como acabamos de ver, estas son las variables por las que se determina el estado trófico de la masa de agua.

En este capítulo se recogen las técnicas más empleadas hasta ahora tanto para detectar las masas de agua continentales, como para monitorizar los parámetros que indican la calidad del agua.

2.1. Detección de las Masas de Agua Continentales

El proyecto de Coordinación de Información sobre el Medio Ambiente “Land Cover” (Coordination of Information on the Environment, CORINE), el cual tiene como objetivo fundamental la creación de una base de datos europea sobre la cobertura y uso del territorio mediante la interpretación a través de imágenes satelitales recogidas, define cinco clases diferentes de coberturas de suelo de primer nivel para la superficie de la Tierra [35]:

1. Superficies artificiales
2. Áreas agrícolas
3. Áreas forestales y seminaturales
4. Humedales
5. Cuerpos de agua

Al igual que la atmósfera, el agua se comporta como un medio absorbente y dispersante, es decir, cuando la radiación incide sobre la superficie acuática, la mayor parte se ve reflejada en una dirección especular a la superficie del líquido, y sólo una pequeña fracción penetra. De esta pequeña fracción, una parte se refleja de forma difusa y puede, por tanto, ser registrada por el sensor del satélite. Esa radiación difusa es la que compone la curva de reflectividad y la que nos interesa para caracterizar la superficie [21].

La curva de reflectividad (o respuesta espectral) del agua (figura 2.2) depende principalmente de su pureza y de la turbidez. La medida de la turbidez indica la presencia de partículas en suspensión en el agua.




Figura 2.2: Espectros de reflectividad del agua “clara” (en azul) y del agua turbia (en rojo). Adaptada de [36].

Como se puede ver en la figura 2.2, el agua absorbe o transmite la mayor parte de la radiación del espectro electromagnético, siendo mayor su absorptividad cuanto mayor es la longitud de onda. La mayor reflectividad del agua clara se produce en el azul, y se reduce paulatinamente hacia el infrarrojo cercano, conforme aumenta la longitud de onda, donde ya es prácticamente nula. Es por ello que la frontera tierra-agua es muy nítida en esta zona espectral [13].

Es decir, la variabilidad de las propiedades del agua se detecta mejor en las longitudes de onda cortas del espectro visible (400 - 800 nm), las cuales se relacionan con la profundidad y con la concentración de sustancias en suspensión, mientras que las masas de agua se diferencian mejor de las superficies terrestres en la franja del infrarrojo cercano o medio, a partir de los 800 nm, donde la reflectividad del agua se reduce sensiblemente.

Existen diversas técnicas para identificar las masas de agua continentales a partir de imágenes satelitales: clasificación supervisada y no supervisada, análisis de componentes principales, técnicas de umbral de histograma, índices espectrales, etc. El método más utilizado hasta ahora, está basado en los índices espectrales. Teniendo en cuenta las características ya comentadas de la signatura espectral del agua, a lo largo de los años se han desarrollado varios índices espectrales multibanda, que maximizan la diferencia entre agua y no agua, y nos ayudan a delinear la frontera entre ambas superficies.

Dado que el cuerpo de agua tiene una fuerte capacidad de absorción y baja radiación en el rango de longitudes de onda de visibles a infrarrojas, McFeeters [37] propuso el **Índice Normalizado Diferencial de Agua** (Normalized Difference Water Index, NDWI), diseñado para, por un lado maximizar la reflectancia del cuerpo de agua en la banda verde y por otro minimizar la reflectancia del cuerpo de agua en la banda NIR (Near Infrared). El índice se define como:

$$NDWI = \frac{\rho_{green} - \rho_{NIR}}{\rho_{green} + \rho_{NIR}} \quad (2.1)$$

donde ρ_{green} es el valor de reflectancia de la banda verde y ρ_{NIR} es el valor de reflectancia de la banda NIR. En comparación con los números digitales (ND) de los píxeles sin procesar, la reflectancia TOA es más adecuada para calcular el NDWI [38, 39].

Más adelante, y para corregir pequeñas deficiencias en el índice NDWI, el cual es sensible a las tierras urbanizadas y a menudo da como resultado cuerpos de agua sobreestimados, se desarrolló el **Índice Normalizado Modificado Diferencial de Agua** (Modified Normalized Difference Water Index, MNDWI), [40], que utiliza la banda de infrarrojo de onda corta, SWIR, como reemplazo de la banda NIR utilizada en NDWI. La motivación es que el cuerpo de agua tiene una capacidad de absorción más fuerte en la banda SWIR que en la banda NIR.

El índice MNDWI se define como:

$$MNDWI = \frac{\rho_{green} - \rho_{SWIR}}{\rho_{green} + \rho_{SWIR}} \quad (2.2)$$

donde ρ_{SWIR} es el valor de reflectancia del infrarrojo de longitud de onda corta.

Varios trabajos de investigación anteriores ya han demostrado que MNDWI es más adecuado para captar la información que indica la presencia de agua, y puede extraerlos con mayor precisión que el NDWI [38, 40, 41].

También son varios los métodos desarrollados en los últimos años para obtener máscaras de agua de imágenes espectrales utilizando técnicas de machine learning. Métodos de clasificación supervisados tales como clasificación de máxima verosimilitud (MLC, Maximum Likelihood Classifier) [42], árboles de decisión (DT, Decision Trees) [43], redes neuronal artificiales (ANN, Artificial Neural Network) y máquinas de vectores de soporte (Support Vector Machines, SVM) [44], utilizados para obtener una imagen segmentada semánticamente con múltiples clases de un conjunto de entrenamiento de píxeles seleccionados. Las técnicas de umbral de histograma, como el umbral de Otsu [45] o la Segmentación de histograma (Histogram Segmentation, HS) [46], también se utilizan para obtener una delimitación de la máscara de agua más precisa, que puede optimizarse utilizando puntos de control (Ground Control Points, GCP).

2.2. Monitorización de la calidad del agua

El color de una masa de agua, es decir, la radiación espectral que emite o refleja el agua, es el resultado de la dispersión y absorción de la luz visible por el agua como sustancia química, así como por las propiedades de los componentes orgánicos e inorgánicos disueltos en ella [47, 48].

Múltiples estudios demuestran la viabilidad de monitorizar la calidad de las masas de agua mediante la medición o cuantificación indirecta de parámetros que reflejan la presencia de sustancias disueltas o partículas en suspensión, debido a que estas modifican las propiedades ópticas del agua [49, 50, 51]. Incluso se han realizado estudios con el objetivo de enumerar cuales serian las características ideales de un sensor, para poder monitorizar la calidad del agua [52]. La mayoría de estos estudios se centran en las que se conocen como variables ópticamente activas, tales como la concentración de clorofila-a (Chl-a), los sólidos suspendidos totales (SST) o la turbidez; ya que son los parámetros más directamente relacionados con la reflectancia observada debido a los procesos de absorción y dispersión [53].

Debe aclararse que la reflectancia observada se ve modificada por los procesos de absorción y dispersión debido a que no se debe únicamente a la reflexión especular que se produce en la superficie del agua, si no que también contribuyen la radiación dispersada por las partículas de las capas intermedias del agua (Figura 2.3) e incluso, dependiendo de la profundidad de la columna de agua, la reflexión en el fondo.

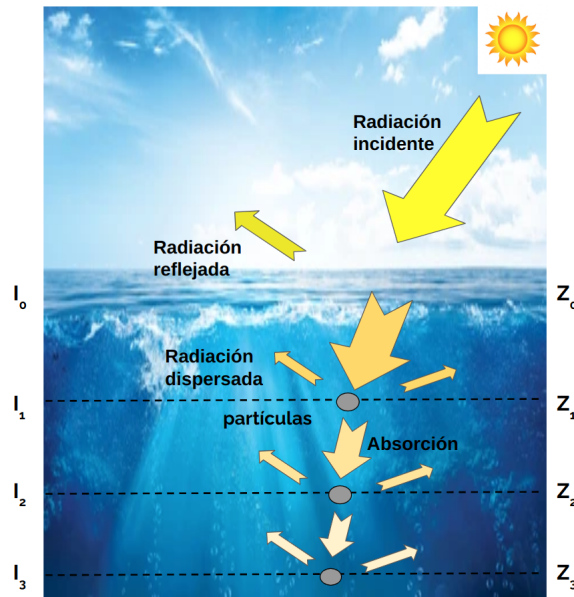


Figura 2.3: Esquema de los procesos de absorción y dispersión sufridos por la radiación en el agua.

No obstante, la teledetección de estos OAC (Constituyentes Ópticamente Activos), en lagos y embalses no es sencilla debido a que en estas masas de agua deben considerarse otros factores independientes de los niveles de fitoplancton [54, 48].

Los principales inconvenientes que se pueden citar son [52]:

- La reflectancia, por lo general, es baja (<5%), lo cual exige que el sensor tenga una elevada resolución radiométrica y un cociente señal-ruido apropiado. También se necesita una adecuada corrección atmosférica, para evitar interferencias que puedan falsear los datos.
- Las moléculas de agua absorben intensamente la radiación infrarroja, limitando el rango de detección espectral de los sensores a la región visible y al infrarrojo cercano [13].

- Los máximos de absorción y de reflexión de pigmentos tales como la clorofila, ocurren en rangos espectrales estrechos (<20 nm), lo que requiere de una buena resolución espectral, en bandas estrechas.
- Por lo general, y debido al limitado rango de detección espectral disponible, se pueden producir solapamientos en los espectros de absorción y dispersión de las diferentes variables ópticamente activas.

Los constituyentes ópticamente activos, OAC, de mayor interés son aquellos que pueden informar acerca del estado ecológico de la masa de agua y de su grado de contaminación, como la concentración de clorofila-a, la cual se correlaciona con la biomasa total del fitoplancton, la turbidez o la materia orgánica disuelta, pero también debe recordarse que hay otras variables relevantes como la temperatura, el pH, el nitrógeno amoniacal ($\text{NH}_3\text{-N}$) o el nitrógeno nitrato ($\text{NO}_3\text{-N}$), y especialmente el nitrógeno total (TN) y el fósforo disuelto [55].

En esta sección se examinan los enfoques más comúnmente empleados para la detección de estos OAC.

2.2.1. Clorofila

Las clorofilas (Chl) son una familia de pigmentos de color verde que se encuentran en las cianobacterias y en todas las algas fotosintéticas [56]. Estos pigmentos puede detectarse fácilmente gracias a su comportamiento frente a la luz, dado que presentan dos zonas diferentes de absorción en los extremos del espectro electromagnético visible, la primera cerca de 450 nm (banda del azul) y la segunda aproximadamente en 670 nm (banda del rojo), produciendo un pico máximo de reflectancia cerca de los 560 nm (banda del verde).

La clorofila constituye por lo general el 2% del peso seco de las algas planctónicas, aunque tanto este porcentaje como el tipo de clorofila o la relación entre los diferentes tipos, difieren según las familias de algas. Los tipos de clorofilas conocidos son a, b, c, d y f, si bien los más comunes son la clorofila-a (Chl-a) y la clorofila-b (Chl-b), siendo la Chl-a la especie abundante, y la Chl-b la especie menor (por lo general $\frac{\text{Chl-a}}{\text{Chl-b}} \sim 3$).

Es por ello que la concentración de clorofila-a sea uno de los parámetros más utilizados para determinar el nivel de eutrofización en el agua, y para estimar, de forma indirecta, el contenido de biomasa [57]. También es un buen indicador del grado de contaminación de los ecosistemas acuáticos y un importante índice del estado fisiológico del fitoplancton [58]. La concentración Chl-a también es, ciertamente, uno de los parámetros más comúnmente monitorizados a partir de las imágenes satelitales.

A continuación se presenta el espectro de absorción (figura 2.4) correspondiente a una muestra de agua con una concentración muy alta del alga verde *Chlorella vulgaris*, una de las más comunes en masas de agua dulce. El principal pigmento fotosintético presente en este tipo de alga es la clorofila-a.




Figura 2.4: Espectro de absorción de una muestra de agua con una concentración de 25 mg/l del alga verde *Chlorella vulgaris*.

Como se puede ver en la figura 2.4, el espectro presenta máximos de absorción producidos por la clorofila-a, 447 nm (banda del azul) y 687 nm (banda del rojo), y por la clorofila-b, 498 nm (banda del azul) y 653 nm (banda del rojo).

Este espectro es el causante de que el color del agua cambie progresivamente de azul a verde a medida que se incrementa la concentración de clorofila en el agua, debido a que las altas concentraciones se reduce la reflectancia en longitudes de onda azules y se incrementa en el verde [59, 60, 61, 62].

Como se refleja en la literatura, son varias las relaciones entre bandas explotadas para estimar la concentración de clorofila. Algunas de las más utilizadas son:

1. El pico de reflectancia a 675 nm debido a la absorción en 687 nm. Esta relación se ha utilizado para desarrollar una variedad de algoritmos para recuperar la concentración de clorofila-a en aguas turbias.
2. La relación entre la banda verde (500-600 nm) y roja (600-700 nm) o viceversa [63, 64].
3. La relación entre azul (400-500 nm) y rojo o viceversa [64].

Si hablamos de ecuaciones utilizadas, también son varias las relaciones matemáticas entre bandas desarrolladas, si bien una de las más utilizadas puede ser el MCI (Maximum Chlorophyll Index) [65].

$$MCI = R_{rs}(\lambda_2) - R_{rs}(\lambda_1) \left[\frac{\lambda_2 - \lambda_1}{\lambda_3 - \lambda_1} R_{rs}(\lambda_3) - R_{rs}(\lambda_1) \right] \quad (2.3)$$

donde $R_{rs}(\lambda_1)$, $R_{rs}(\lambda_2)$ y $R_{rs}(\lambda_3)$ son las reflectancias medidas a 665, 705 y 740 nm (bandas 4, 5 y 6 del satélite Sentinel-2).

2.2.2. Concentración de sustancias orgánicas disueltas

En altas concentraciones estos compuestos absorben fuertemente en el espectro cercano a UV y del violeta al verde-azul, lo que hace que puedan afectar significativamente, y colorear el agua de un color marrón amarillento [66].

El espectro de absorbancia de CDOM puede superponerse a la absorción producida por la clorofila, y puede representar más del 50 % de la absorción total a 443 nm, que es útil para estimar la concentración de clorofila [67].

El aumento en la concentración afecta principalmente los valores de reflectancia en la región azul y verde del espectro (especialmente por debajo de 500 nm) y su absorbancia aumenta al disminuir la longitud de onda. A altas concentraciones de CDOM, la absorbancia del espectro de luz roja puede ser también significativa.

La teledetección de CDOM es importante en el estudio de la ecología acuática y la dinámica del carbono debido a que afecta a la transparencia del agua y a la profundidad a la cual los rayos solares penetran en la columna de agua. Algunas de las relaciones entre bandas desarrolladas para estimar esta variable son:

- Relación entre la banda azul (400–500 nm) y la banda verde (500–600 nm)
- Relación entre la banda verde (500–600 nm) y la banda roja (600–700 nm)

2.2.3. Turbidez

La turbidez es una propiedad óptica del agua, que dispersa y absorbe la luz en lugar de transmitirla en línea recta. Los sedimentos suspendidos son responsables de la mayor parte de la dispersión, mientras que la absorción, como hemos visto, está controlada por la concentración de clorofila-a y la materia disuelta o particulada. Como la turbidez del agua es principalmente el resultado de la presencia de materia suspendida, la medición de la turbidez a menudo se ha utilizado para calcular las concentraciones de sedimento suspendido. Cuantas más partículas en suspensión, más difícil es que la luz viaje a través del agua y, por lo tanto, mayor es su turbidez. La unidad de medida de la turbidez es el acrónimo NTU (Nephelometric Turbidity Unit).

La turbidez y las materias suspendidas totales se consideran variables importantes en muchos estudios debido a su vinculación directa con la cantidad de luz solar que penetra en el agua, que a su vez afecta a la fotosíntesis y al crecimiento de algas y plancton.

La estrategia más utilizadas para la estimación de la turbidez mediante teledetección es [68, 69] la calibración de distintos índices espectrales adaptados a partir de las bandas: 490, 560 y 705 nm.

La transparencia del agua también puede ser estimada a través de lo que se conoce como “la profundidad de visión del disco de Secchi, (SD)”, medido en m, y que se define como la profundidad a la que el ojo humano deja de ver un disco metálico de 20 cm de diámetro con un pato blanco y negro que ayuda a mejorar el contraste (figura 2.5).



Figura 2.5: Disco Secchi. Objeto utilizado para estimar la turbidez o la transparencia del agua.

Este parámetro es un buen indicador de la profundidad a la que la luz solar penetra en el agua [70], y exhibe una correlación inversa con la cantidad de sólidos en suspensión presentes en los cuerpos de agua.

Los principios de atenuación de la luz en el agua son los que controlan la disminución de la energía radiante conforme aumenta la profundidad [71], y la literatura existente muestra que las correlaciones más utilizadas, aprovechan el área que se genera entre una línea base establecida, y el pico del espectro entre 400 y 750 nm.

Así pues, la profundidad del disco de Secchi se puede estimar mediante teledetección estableciendo relaciones con bandas espectrales únicas, o mediante relaciones entre varias bandas.

1. Medidas de bandas situadas entre: 445 y 530 nm (azul), 520 y 610 nm (verde) y 640 y 720 nm (rojo).
2. Ratio entre la banda azul (400–500 nm) y la banda verde (500–600 nm).
3. Ratio entre la banda azul (400–500 nm) y la roja (600–700 nm).
4. Ratio entre la banda verde (500–600 nm) y la roja (600–700 nm).

2.2.4. Temperatura

La temperatura del agua es una variable importante que regula los procesos físicos, químicos y biológicos. Alguno de los aspectos más importantes a la hora de analizar este parámetros son: como afecta a las concentraciones de oxígeno disuelto en el agua (la solubilidad del oxígeno disminuye al aumentar la temperatura del agua), el impacto en los procesos de fotosíntesis de las algas y de otras plantas acuáticas, la influencia en la velocidad metabólica (velocidad a la que un organismo utiliza la energía disponible) de los organismos, etc.

La teledetección térmica se basa en la banda térmica infrarroja, 8-14 μm , la cual mide la cantidad de flujo radiante infrarrojo (calor) emitido desde las superficies. Los efectos atmosféricos son el mayor inconveniente a la hora de estimar mediante teledetección la temperatura superficial del agua, ya que los gases presentes en la atmósfera producen una absorción importante que limita la teledetección térmica a dos regiones, de 3 a 5 μm y de 8 a 14 μm . La literatura también indica el uso de esta banda para cuantificar la temperatura del agua [50, 72, 73].

Capítulo 3

Propiedades ópticas del agua en el embalse de “El Val”

La monitorización o cuantificación indirecta mediante teledetección de parámetros utilizados para determinar la calidad del agua tales como las sustancias disueltas, la clorofila, o las partículas en suspensión, se fundamenta en que estos modifican significativamente las propiedades ópticas del agua y la reflectancia observada mediante procesos de absorción y dispersión de la luz [49, 50, 51, 53].

En este capítulo se comienza por resumir las características generales de la masa de agua incluida en este estudio, el embalse de “El Val” (sección 3.1), así como los equipos de medición desplegados y las diferentes medidas tomadas in-situ, realizadas con el fin de calibrar y validar los métodos desarrollados para estimar estas variables.

Seguidamente se estima la influencia que tienen dichas sustancias ópticamente activas en las propiedades del agua mediante un estudio espectroscópico realizado en el laboratorio con muestras de agua recogidas en el embalse analizado. El estudio se realizó sobre el espectro de absorción producido por muestras de agua con diferentes concentraciones de clorofila, ya que como se ha visto en el capítulo anterior (cap. 2), este espectro es particularmente complejo debido principalmente a los diferentes tipos de clorofila presentes en las algas, y a las diferentes sustancias cuyos espectros pueden solaparse con el de la clorofila.

3.1. Embalse de El Val (Zaragoza)

El embalse de “El Val”, figura [3.1](#), construido en Los Fayos, municipio de la Comarca de Tarazona y el Moncayo, en la provincia de Zaragoza (a 89 kilómetros de la ciudad de Zaragoza), Comunidad autónoma de Aragón, entre 1996 y 2001, con una capacidad máxima de 28 Hm^3 , para embalsar el agua del río Val y el río Queiles, ocupa una superficie de 101 hectáreas, con unas dimensiones aproximadas de $3.5 \times 0.3 \text{ km}$ de longitud, y se sitúa entre las coordenadas 41.7847 y 41.8857 latitud norte y -1.8283 y -1.7847 longitud oeste.



Figura 3.1: Imagen del embalse del Val obtenida con el satélite Sentinel-2, satélite de la ESA, el 15/03/2018.

Calificado como eutrófico o hipereutrófico en los informes de seguimiento de calidad de agua de la Confederación Hidrográfica del Ebro (CHE) en los años 2018 [\[74\]](#) y 2019 [\[75\]](#), y considerado uno de los embalses más contaminados de la cuenca, la alta eutrofización de la masa de agua se debe a la gran presencia de nutrientes acumulados en el embalse, en parte por los vertidos que recibe de la EDAR (estación depuradora de aguas residuales) y de las industrias cercanas, y por escorrentías de la actividad ganadera de la zona [\[76\]](#). Además, la falta de lluvia provoca que la entrada de agua limpia proveniente de la cuenca sea escasa, lo que no facilita la renovación del vaso, y agrava aún más los problemas de contaminación.

Como consecuencia de los problemas descritos, y con el objetivo de optimizar las medidas correctoras a implementar, en 2019 la CHE encargó a la PYME Ecohydros S.L. la realización de estudios de mayor resolución espacio-temporal con los que acotar los diferentes agentes causales, e implementar soluciones a la eutrofización del agua. Es en el marco de este trabajo en el que el grupo de computación avanzada y e-Ciencia del IFCA (Instituto de Física de Cantabria) colaboró con esta PYME, y por lo que este estudio se centra en este embalse.

Sistemas de Monitorización

- Sonda perfiladora en cabecera del embalse

Instalada por la empresa ADASA en la zona más cercana a la presa (figura 3.2) por encargo de la Confederación Hidrográfica del Ebro para continuar con el trabajo de seguimiento de la calidad del agua del embalse que ya se venía haciendo desde el año 2010 [76], la sonda “Aquadam” se encuentra operativa desde febrero de 2018.



Figura 3.2: Localización geográfica de la sonda “Aquadam”, situada en la cabecera de la presa del embalse de “El Val”.

La sonda multiparamétrica “Aquadam” integra sensores de medida de parámetros fisicoquímicos tales como: temperatura, pH, conductividad, oxígeno disuelto, potencial redox, turbidez, etc. así como otros parámetros biológicos entre los que se encuentra la clorofila-a (tabla 3.1).

Se cuenta con un sistema automático de posicionamiento en profundidad mediante un tambor motorizado que sitúa la sonda a diferentes profundidades y permite realizar perfiles métricos verticales en toda la columna de agua, en este caso usualmente entre 1 y 35 metros. Por lo general los perfiles se realizan con una frecuencia de 6 horas, 4 veces al día, a las 00:00h, 06:00h, 12:00h y 18:00h.

Los datos de esta plataforma de monitorización son lo que se han utilizado en este trabajo, y se pueden encontrar en abierto en la página web de la Confederación Hidrográfica, concretamente en el enlace: [“Aquadam”¹](#)

¹<http://195.55.247.234/redalerta/embalsesEV.php>

Fecha (hh:mm:ss)	Cota (msnm)	Prof (m)	Temp (°C)	pH	Redox (mV)	Cond ($\mu\text{g}/\text{cm}$)	Ox. disuelto (mg/l)	Turbidez (NTU)	Clorofila-a ($\mu\text{g}/\text{l}$)
14:01:00	606.50	1.05	20.1	8.76	288.0	419.0	8.8	6.3	86.1
14:05:00	605.54	2.02	20.0	8.64	290.0	421.0	7.8	7.6	23.3
14:09:00	604.54	3.02	20.0	8.07	296.0	424.0	5.0	7.9	19.6
14:13:00	603.55	4.01	19.9	7.85	299.0	424.0	4.1	8.0	13.1
14:17:00	602.54	5.01	19.9	7.75	300.0	425.0	3.9	7.9	14.9
14:22:00	601.55	6.01	19.9	7.71	300.0	425.0	3.7	7.9	16.6
14:26:00	600.54	7.02	19.8	7.71	301.0	426.0	3.5	7.6	22.2
14:30:00	599.55	8.01	19.8	7.61	300.0	429.0	3.0	7.8	21.9
14:34:00	598.54	9.02	19.8	7.73	299.0	429.0	3.8	7.7	19.6
14:38:00	597.50	10.06	19.8	7.67	297.0	429.0	3.4	7.8	18.8
14:43:00	596.55	11.01	19.7	7.73	296.0	431.0	3.7	7.8	14.8
14:47:00	595.54	12.02	19.7	7.69	297.0	431.0	3.3	7.8	11.3
14:51:00	594.54	13.01	19.7	7.67	297.0	432.0	3.3	8.0	5.6
14:55:00	593.55	14.01	19.6	7.61	296.0	432.0	2.9	8.0	3.9
14:59:00	592.54	15.02	19.5	7.59	296.0	433.0	2.5	8.0	3.8
14:04:00	591.54	16.01	19.4	7.53	296.0	434.0	2.0	7.9	3.1
14:08:00	590.55	17.01	19.4	7.50	296.0	434.0	1.7	8.0	3.5
14:12:00	589.54	18.02	19.4	7.47	295.0	434.0	1.3	7.7	3.0
14:16:00	588.55	19.01	19.3	7.44	295.0	435.0	1.1	7.6	3.0
14:20:00	587.55	20.01	19.2	7.43	294.0	436.0	0.5	7.5	2.7
14:24:00	586.55	21.01	18.7	7.36	293.0	446.0	0.1	7.5	2.2
14:29:00	585.54	22.01	18.2	7.36	291.0	450.0	0.0	7.8	2.9
14:33:00	584.54	23.02	18.0	7.38	288.0	450.0	0.0	8.0	3.1
14:37:00	583.55	24.01	17.8	7.36	284.0	449.0	0.0	8.0	3.6
14:41:00	582.54	25.01	17.7	7.36	283.0	451.0	0.0	7.9	3.5
14:45:00	581.55	26.01	17.7	7.36	281.0	451.0	0.0	6.4	2.6
14:50:00	580.56	27.00	17.6	7.34	278.0	450.0	0.0	6.7	3.3
14:54:00	579.54	28.02	17.5	7.32	276.0	451.0	0.0	6.3	3.1
14:58:00	578.54	29.02	17.4	7.35	272.0	452.0	0.0	6.3	3.8
14:02:00	577.54	30.01	16.9	7.33	269.0	451.0	0.0	6.5	3.3
14:06:00	576.54	31.01	15.3	7.30	264.0	460.0	0.0	6.3	3.8
14:11:00	575.54	32.01	13.2	7.31	264.0	467.0	0.0	6.5	3.9
14:15:00	574.55	33.00	11.8	7.35	177.0	467.0	0.0	7.6	4.3
14:19:00	573.54	34.01	10.6	7.38	53.0	469.0	0.0	8.7	3.3

Tabla 3.1: Ejemplo de los datos tomados durante el perfil métrico vertical realizado por la sonda “Aquadam” el día 30/09/2021. Puede apreciarse la estratificación térmica y los altos valores de clorofila, así como la anoxia en profundidad como corresponde a un embalse hipereutrófico.

■ Muestreos puntuales

Durante los estudios realizados por la empresa Ecohydros en 2019 se seleccionaron 12 puntos de muestreo distribuidos a lo largo del embalse, en los cuales se hicieron campañas puntuales de medición de los parámetros de calidad del agua.

Estos puntos se seleccionaron para captar en cada campaña de medición, toda la heterogeneidad que presentan los indicadores de calidad del agua en diferentes puntos del embalse. Estas medidas han sido muy relevantes para este trabajo, ya que una de las mayores ventajas que aporta la teledetección a este tipo de estudios es la estimación de los diferentes indicadores a lo largo de toda la superficie en una sola medida. De este modo, se ha podido disponer de medidas simultáneas (o cuasi-simultáneas) a fin de comparar las estimaciones realizadas mediante teledetección en varios puntos independientes distribuidos por toda la superficie del embalse, lo que permite generar mapas de dichos indicadores más precisos.

La distribución espacial de estos muestreos puntuales se pueden ver en la figura [3.3](#), y las coordenadas se recogen en la tabla siguiente [\(3.2\)](#).



Figura 3.3: Localización geográfica del área de estudio y distribución de los puntos de muestreo de parámetros ambientales y de toma de datos.

Punto de Muestreo	Latitud	Longitud
E1	41.8764	-1.7894
E2	41.8776	-1.7898
E3	41.8744	-1.7904
E4	41.8779	-1.7976
E5	41.8793	-1.7982
E6	41.8765	-1.7978
E7	41.8816	-1.8090
E8	41.8806	-1.8090
E9	41.8795	-1.8092
E10	41.8803	-1.8205
E11	41.8798	-1.8212
E12	41.8810	-1.8235

Tabla 3.2: Coordenadas de los puntos de muestreo seleccionados a lo largo del embalse de “El Val”.

La toma de medidas de las diferentes campañas de medición consistieron en perfiles metro a metro de parámetros fisicoquímicos tales como la temperatura, la conductividad eléctrica, la salinidad, el pH, el oxígeno disuelto, la concentración de clorofila-a medida mediante fluorescencia y el potencial redox, mediante la sonda multiparamétrica “Hydro-lab”, de características similares a la sonda “Aquadam”.

Las medidas se realizaron en todos los puntos disponibles, ya que dependiendo del nivel del agua en el momento de la campaña, algunos de los puntos quedaban inhabilitados.

3.2. Estudio Espectroscópico

Como se avanzó en el capítulo anterior (cap [2](#)), el espectro de absorción de una muestra de agua como la del embalse de “El Val” puede ser muy complejo. Por ello, y para entender la relación entre las propiedades ópticas del agua en el embalse y la concentración de clorofila presente en ella como indicador de su calidad, se ha realizado un estudio en laboratorio utilizando técnicas espectroscópicas.

La **espectrofotometría** es una técnica analítica utilizada para estimar cuánta luz absorbe una sustancia química, midiendo la diferencia de intensidad de un haz de luz cuando este pasa a través de la solución muestra, figura [3.4](#).




Figura 3.4: Esquema del proceso de medición o cuantificación indirecta por espectrofotometría.

La muestra absorbe parte de la radiación incidente, transmitiendo menor energía radiante. En esta técnica se mide, por tanto, la cantidad de luz absorbida como función de la longitud de onda utilizada. La absorción de las radiaciones ultravioletas, visibles e infrarrojas depende de la estructura de las moléculas presentes en el agua (la sustancia a analizar), y es característica de cada sustancia química. Este es el método de análisis óptico más usado en las investigaciones biológicas.

El espectrofotómetro, figura [3.5](#), es el instrumento que permite comparar la radiación absorbida o transmitida por una solución muestra que contiene una cantidad desconocida de soluto, y una que contiene una cantidad conocida de la misma sustancia.

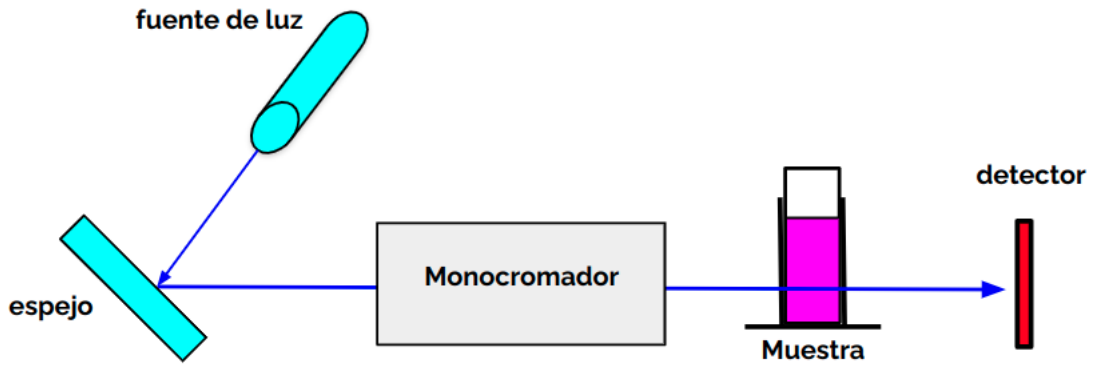


Figura 3.5: Esquema del funcionamiento de un espectrofotómetro.

El espectrofotómetro empleado durante este estudio fue el modelo Cary 6000i UV-Vis-NIR (figura 3.6), un espectrofotómetro de doble haz en el que las medidas de la intensidad de cada haz, I_0 e I , a partir de las cuales se calcula la absorbancia ($A(\lambda)$), se realizan de forma simultánea.




Figura 3.6: Esquema del funcionamiento de un espectrofotómetro de doble haz.

El funcionamiento del Cary 6000i es sencillo: se transforma la luz procedente de la lámpara en un haz monocromático mediante un filtro monocromador, para a continuación dividir éste en dos haces diferentes que atraviesan simultáneamente la muestra de estudio (I) y la muestra patrón (I_0).

Una vez los haces han atravesado las muestras, estos emergen con diferentes intensidades $I(\lambda)$, $I_0(\lambda)$, y pasan por un fotodetector y un amplificador que transforma la intensidad de luz recibida en señales eléctricas amplificadas. Finalmente, el software del equipo convierte automáticamente la transmitancia en absorbancia obteniendo así los espectros de absorción, en los que se representará absorbancia, $A(\lambda)$ (eje de ordenadas), frente a la longitud de onda, λ (eje de abscisas).

Aunque este montaje permite realizar medidas dentro del rango comprendido entre 170 y 1800 nm, dado que el dispositivo está dotado de dos lámparas (dos fuentes de luz distintas), una halógena para VIS/IR y una de deuterio para el UV, en nuestro caso, el rango del espectro electromagnético utilizado ha sido el correspondiente al visible, entre 400 y 800 nm.

3.2.1. Ley de Beer-Lambert

La ley que estudia cómo la intensidad del haz de luz se va atenuando a medida que atraviesa la cubeta debido a la absorción de las moléculas de la muestra, es la ley de Beer-Lambert [77, 78], que se describe a continuación por completitud didáctica de este trabajo.

El ritmo de absorción depende de la intensidad inicial de luz y de la concentración de moléculas. De este modo, cuando un haz de luz de intensidad I recorre una distancia dL en una muestra con una concentración molar c , la atenuación de la intensidad dI viene dada por la expresión:

$$dI = -\kappa \cdot c \cdot I \cdot dL \quad (3.1)$$

donde κ se denomina coeficiente de absortividad molar, y es una propiedad característica de cada sustancia correspondiente a la cantidad de radiación que absorbe a una longitud de onda determinada por unidad de concentración. La expresión anterior también se puede expresar en su forma integral, lo que da lugar a la ley de Beer-Lambert para la absorción:

$$\frac{dI}{I} = -\kappa \cdot c \cdot dL \Rightarrow \int_{I_0}^I \frac{dI}{I} = -\kappa \cdot c \cdot \int_0^L dL \Rightarrow \ln \frac{I_f}{I_0} = -\kappa \cdot c \cdot dL \quad (3.2)$$

la expresión final viene dada por la ecuación:

$$I_f = I_0 \cdot e^{-\kappa \cdot c \cdot dL} \quad (3.3)$$

o lo que es lo mismo, una expresión relaciona la absorción, la intensidad a la salida de la muestra I_f , la intensidad inicial I_0 , la concentración de moléculas c y la distancia recorrida por la luz en la muestra, L .

El espectrofotómetro, en lugar de la intensidad, mide la absorbancia A que se define por:

$$A \equiv \ln \frac{I_f}{I_0} = -\kappa \cdot c \cdot dL \quad (3.4)$$

Aunque lo más habitual en espectrofotometría es hablar en términos de absorbancia, es directo definir la transmitancia como:

$$T = \frac{I_f}{I_0} \quad (3.5)$$

este término suele expresarse como porcentaje de luz transmitida.

3.2.2. Estudio Espectrofotométrico

Se diseñó, por tanto, un experimento con el objetivo de entender cómo afecta a las propiedades ópticas del agua de “El Val” la concentración de clorofila, y además, para analizar la posición de las bandas espectrales de los satélites Sentinel-2 y Landsat 8 en función de sus bandas de absorción. El estudio consistió en caracterizar el espectro de absorción producido por diferentes muestras de agua del embalse con diferentes concentraciones de clorofila.

Las concentraciones de clorofila a analizar se escogieron en función de los límites establecidos por la OCDE para determinar los niveles tróficos en embalses y lagos, tabla 2.1, de tal modo que la máxima concentración de las diluciones ($50\mu\text{gr}/l$) se corresponde a un nivel trófico hipereutrófico, y la concentración más pequeña ($2,5\mu\text{gr}/l$) a un nivel Ultraoligotrófico.

Para la preparación de las diluciones a diferentes concentraciones se procedió a tomar una muestra de agua directamente en el embalse de “El Val”, y añadir concentraciones conocidas de clorofila, consiguiendo así diluciones escalonadas. Los pasos a seguir para la realización del experimento fueron:

1. Determinar la concentración de clorofila de la muestra original de agua.
2. Estudiar el espectro de absorción de las muestras de agua y su evolución en función de la concentración de clorofila presente en las distintas muestras.

Las muestras de agua contenían el alga *Chlorella Vulgaris*, una de las especies más comunes en las floraciones de algas en agua dulce. La dependencia de la concentración de clorofila en el tipo de alga en las floraciones es otro dato importante a tener en cuenta, pues como se vio en el anterior capítulo (cap. 2), las diferentes poblaciones de algas pueden incorporar diferentes concentraciones de clorofila a, b, c1, c2 y d.

Estudio del espectro de absorción de la clorofila.

Se recogió, por tanto, para el estudio una muestra de 4l de agua del embalse de “El Val”, y se midió la concentración de algunas de las variables OAC más importantes presentes en la muestra mediante una sonda multiparamétrica igual a la utilizada en los muestreos puntuales. Los resultados de las mediciones se presentan a continuación (tabla 3.3):

Temp (°C)	pH	Cond ($\mu S/cm$)	Clorofila-a ($\mu gr/l$)	Turb (NTUs)
10.9	8.6	501	8.0	1.4

Tabla 3.3: Medidas físico-químicas realizadas con la sonda multiparamétrica “Hydrolab”, en la muestra de agua original tomada en el embalse de El Val.

Aunque los resultados obtenidos se corresponden con los de una muestra de agua “clara”, que no presenta una gran cantidad de clorofila ni otros factores que pudiesen haber alterado las medidas de los espectros, como por ejemplo una alta turbidez, antes de continuar con el estudio y preparar las diferentes diluciones se procedió a filtrar la muestra de agua para eliminar todos los componentes presentes en ella, y centrar el estudio en las propiedades y el comportamiento de la clorofila.

Se presenta a continuación la tabla con las diferentes diluciones preparadas, tabla 3.4. Como ya se ha comentado, la concentración de las muestras se escogieron en función de los límites establecidos por la OCDE para los diferentes niveles tróficos.

En la preparación de las diferentes diluciones se comenzó una suspensión muy concentrada (2.5mg/l de alga o 50 $\mu gr/l$ de clorofila), y se fue diluyendo sucesivamente con agua de la muestra hasta alcanzar la preparación más diluida (0.125mg/l de alga o 2,5 $\mu gr/l$ de clorofila).

Recordemos que, por lo general, la clorofila constituye por lo general, el 2% del peso seco de las algas planctónicas, siendo la Chl-a la especie abundante, y la Chl-b la especie menor ($\frac{Chl-a}{Chl-b} \sim 3$).

Nivel trófico	Conc. alga (mg/l)	Conc. clorofila ($\mu\text{gr/l}$)	Conc. clorofila-a ($\mu\text{gr/l}$)
Hipereutrófico	2.5	50	~ 35
Hipereutrófico	2.25	45	~ 31,5
Hipereutrófico	1.875	37.5	~ 26,25
Eutrófico	1.25	25	~ 17,5
Eutrófico	0.625	12.5	~ 8,75
Mesotrófico	0.375	7.5	~ 5,25
Mesotrófico	0.25	5	~ 3,5
Oligotrófico	0.125	2.5	~ 1,75

Tabla 3.4: Diluciones de clorofila preparadas a diferentes concentraciones. En la tabla se representan tanto las concentraciones de alga como las concentraciones de clorofila y clorofila-a, así como el nivel trófico asociado a dichas concentraciones.

Antes de proceder con el análisis de las diluciones presentadas, se estudió una primera dilución preparada con una concentración muy alta de clorofila, 25 mg/l de alga o bien 500 $\mu\text{g/l}$ (figura 3.7), la cual está muy por encima de los valores establecidos en los diferentes niveles tróficos. Esta muestra equivaldría a un nivel hipereutrófico, pero muy por encima del nivel mínimo fijado. El objetivo de analizar primero esta muestra es el de presentar claramente los cambios producidos en el espectro de absorción por la concentración de clorofila.

Cabe mencionar que, puesto que el Cary 6000i es un espectrofotómetro de doble haz, para obtener este espectro se colocó una muestra de agua filtrada como muestra patrón (o muestra de referencia), y la muestra con alta concentración de clorofila como muestra a analizar. Por tanto, el espectro de absorción que se muestra en la figura se corresponde con la diferencia de absorción entre ambas muestras para cada longitud de onda, o lo que es lo mismo, el espectro muestra lo que la muestra a analizar absorbe, que la muestra de referencia no.

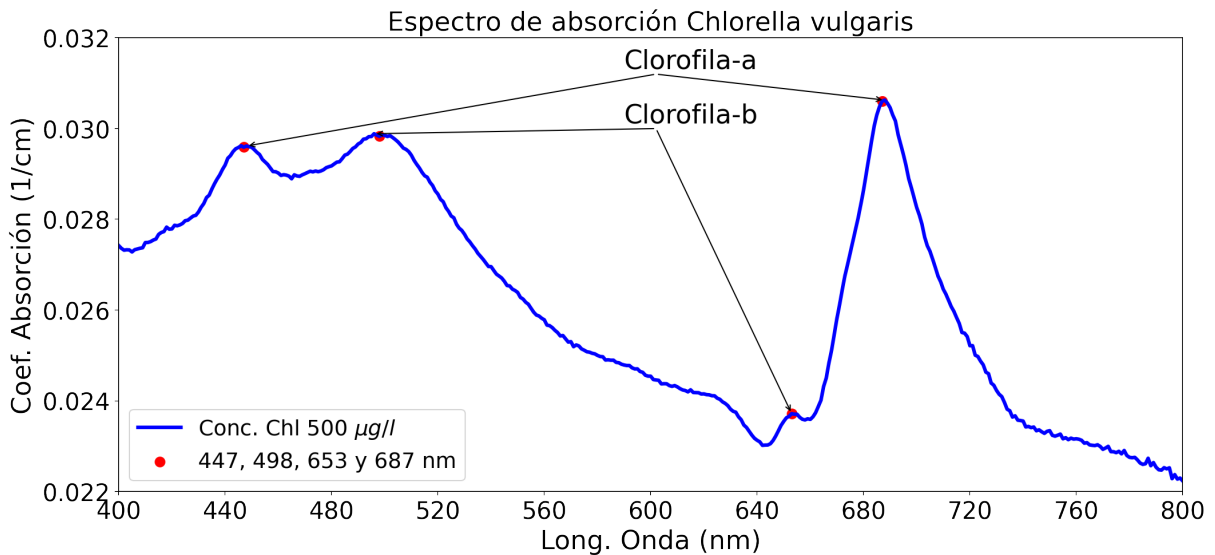


Figura 3.7: Espectro de absorción (en azul) de una solución de clorofila disuelta en agua a una concentración de 500 $\mu\text{gr/l}$. Se representan en color rojo los máximos de absorción registrados en el espectro.

El espectro muestra claramente las bandas de absorción producidas por la clorofila y las longitudes de onda donde se producen los máximos de absorción. Los diferentes tipos de clorofila tienen típicamente dos grupos de absorción en el espectro visible:

1. La primera en el rango correspondiente a al azul (400 - 500 nm), con los máximos de absorción situados en 447 y 498 nm.
2. La segunda correspondiente al rango del rojo (600 - 700 nm), con los máximos de absorción situados sobre los 653 y 687 nm.

También es fácil distinguir como estos mismos tipo de clorofila reflejan toda la parte central del espectro visible (el color verde) 500 - 600 nm.

Estas marcadas características del espectro de absorción de la clorofila, algo que nos encontraremos de forma recíproca en el de reflexión, es lo que la teledetección en general y los satélites con sensores multispectrales en particular, tratan de caracterizar a la hora de estimar la concentración de clorofila en el agua.

Si representamos el espectro y la distribución de las bandas espectrales de los dos satélites utilizados en este trabajo (Sentinel-2 y Landsat 8), figura 3.8, podemos ver donde se sitúan estas en función de las diferentes zonas de absorción y reflexión caracterizadas para la clorofila.

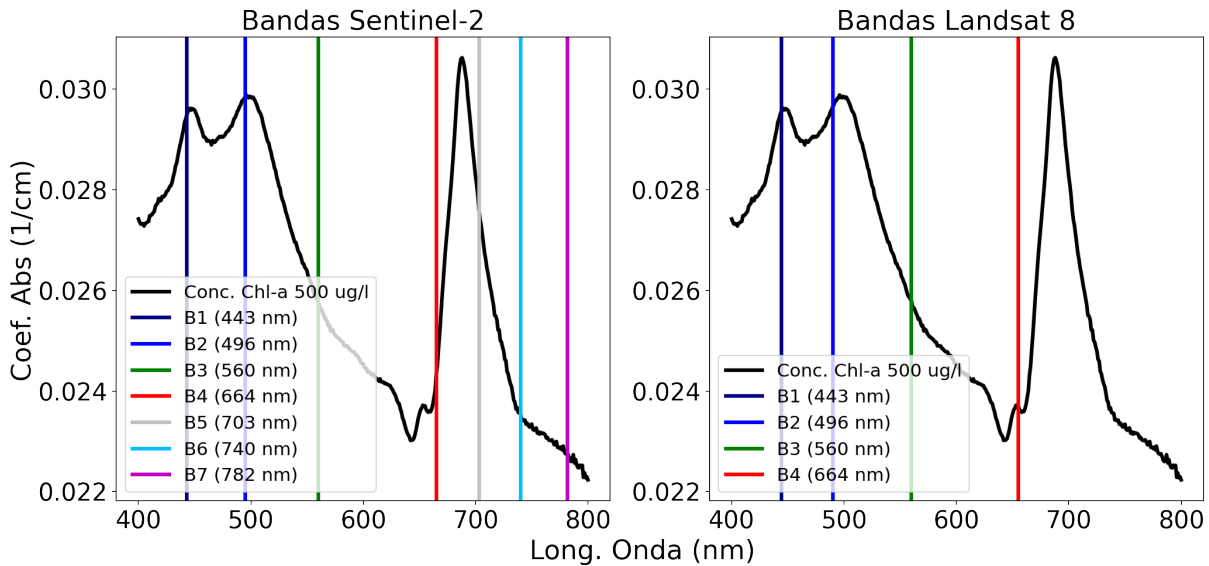


Figura 3.8: Bandas espectrales de los satélites Sentinel-2 y Landsat 8 sobre el espectro de absorción (en negro) de una dilución a alta concentración de clorofila.

Podemos ver como las 4 primeras bandas de ambos satélites se sitúan en zonas sensibles del espectro, las bandas 1 y 2 situadas en los máximos reflejados en la zona entre 400 - 500 nm, la banda 3 (verde) situada en la zona de reflexión, y la banda 4 (rojo) en una zona donde la absorción es mínima, si bien el satélite Sentinel-2 tiene además, 3 bandas mapeando de forma precisa el pico de absorción producido entre 600 - 700 nm.

Esta diferencia da ventaja al satélite Sentinel-2 frente a Landsat 8, y puede resultar muy importante a la hora de estimar la concentración de clorofila ya que como vemos es la banda de absorción más abrupta de las 3 que podemos encontrar en el espectro.

Una vez analizado este espectro y comprobada la ventaja que tiene la resolución espectral del Sentinel-2 para monitorizar la clorofila pasamos, ahora si, al análisis de los diferentes espectros producidos por muestras de agua asociados a los diferentes niveles tróficos en función de la concentración de clorofila.

El objetivo de esta parte del experimento es el de estudiar la evolución de las bandas de absorción observadas en la figura anterior [3.7](#), en diferentes diluciones preparadas a distinta concentración de clorofila. Se presentan, por tanto, a continuación los espectros de absorción obtenidos para algunas de las muestras preparadas con diferentes concentraciones de clorofila [3.4](#).

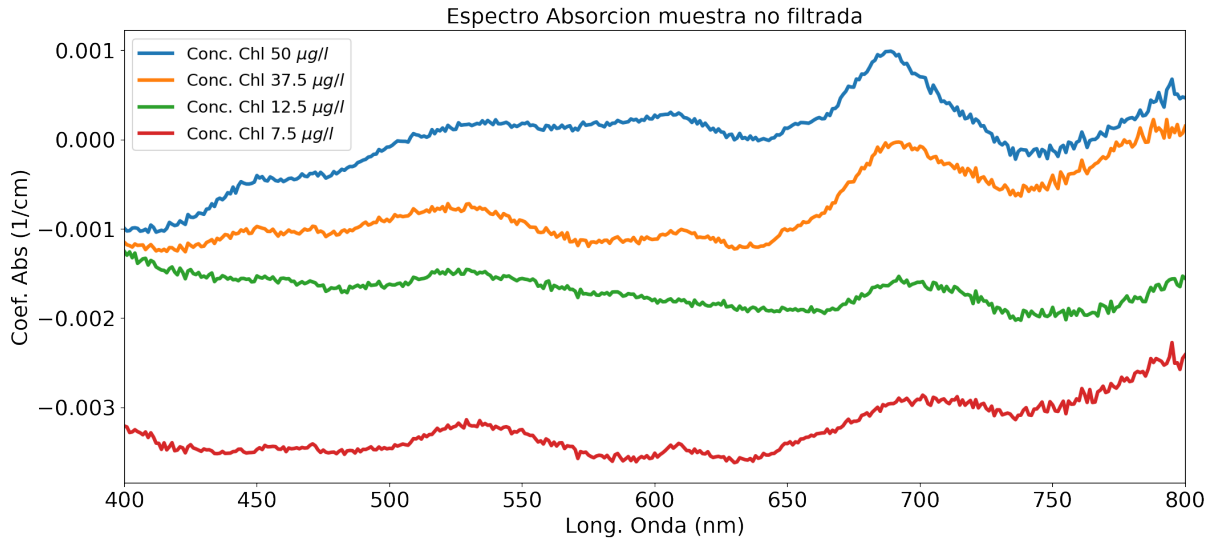


Figura 3.9: Espectros de absorción obtenidos con el espectrofotómetro Cary 6000i para distintas diluciones preparadas con diferentes concentraciones de clorofila. En azul se representa la dilución con una concentración de $50 \mu\text{g/l}$, en naranja $37.5 \mu\text{g/l}$, en verde $12.5 \mu\text{g/l}$ y en rojo $7.5 \mu\text{g/l}$

Aunque estos espectros están sujetos a pequeñas desviaciones en los valores de la absorción, ya que lo que se mide son muestras líquidas, esta figura nos permite realizar un primer análisis cualitativo sobre el comportamiento del espectro con la concentración de clorofila.

La primera característica a destacar es que, de acuerdo a lo esperado, todos los espectros producidos por las diferentes muestras asociadas a los diferentes niveles tróficos son claramente diferenciables entre ellos.

También podemos destacar como, claramente, las tres bandas de absorción van decreciendo a medida que decrece la concentración de clorofila de las muestras. Este efecto se puede ver en la banda de absorción de 600 - 700 nm, ya que esta es la más pronunciada del espectro, o en la banda correspondiente al azul (400 - 500 nm), la cual llega incluso a desaparecer a bajas concentraciones.

Sin embargo, para realizar un correcto un análisis cuantitativo de estas bandas de absorción, tenemos que fijarnos en el área de dichas bandas y no en el valor que toma el máximo de la función, ya que lo que es proporcional a la concentración de clorofila presente en la muestra es el área bajo la función producida.

Para poder analizar el área de estas bandas correctamente, debemos por tanto aislar estos picos o bandas de absorción y estudiarlos por separado. Más si tenemos en cuenta que los diferentes picos de absorción los producen diferentes tipos de clorofila. Como se ha visto anteriormente, los picos observados en 447 y 687 nm se corresponden con clorofila-a, y los observados en 498 y 653 nm a la clorofila-b.

Para aislar correctamente las diferentes bandas y poder analizarlas, trazamos “líneas base” entre los mínimos que acotan las diferentes bandas, y analizamos sólo el pico desde las líneas base tomadas. A continuación se muestra en la figura 3.10 un ejemplo de cómo se han trazado las “líneas base” para aislar los picos de absorción y analizarlos de forma correcta.




Figura 3.10: Representación gráfica del procedimiento seguido para aislar los picos de absorción encontrados en el espectro.

Para calcular de forma correcta el área de estas bandas se ajustaron funciones de forma paramétrica a la gráfica, de forma que se obtenga el mejor ajuste posible. El análisis cuantitativo sólo se han realizado para los 3 picos de absorción mostrados en la figura anterior, debido a que el pico situado en 640 nm es demasiado pequeño y se pierde a concentraciones bajas.

Se tomó además la decisión de realizar 10 medidas del área para cada una de las bandas, variando de 0,5 nm en 0,5 nm los mínimos que se tomaban para trazar las “líneas base”, y tomar la media aritmética como medida más aproximada. Esto nos facilita estimar la incertidumbre obtenida al estimar la medida del área.

Analizando de la forma mencionada las bandas de absorción encontradas en las diferentes diluciones, tenemos:

Conc. alga (mg/l)	Conc. Chl ($\mu g/l$)	$\lambda = 447\text{nm}$		$\lambda = 498\text{nm}$		$\lambda = 687\text{nm}$	
		Área media	std	Área media	std	Área media	std
2.5	50	0.0031	0.0007	0.0062	0.0008	0.0161	0.0019
2.25	45	0.0014	0.0005	0.0069	0.0010	0.0169	0.0019
1.875	37.5	0.0021	0.0007	0.0072	0.0009	0.0146	0.0015
1.25	25	0.0018	0.0008	0.0042	0.0006	0.0149	0.0017
0.625	12.5	0.0017	0.0009	0.0041	0.0009	0.0094	0.0010
0.375	7.5	0.0008	0.0003	0.0049	0.0008	0.0069	0.0008
0.250	5	0.0012	0.0005	0.0045	0.0009	0.0069	0.0008
0.125	2.5	0.0006	0.0003	0.0036	0.0011	0.0061	0.0008

Tabla 3.5: Análisis del comportamiento de las bandas de absorción de 447, 498 y 687 nm.




Figura 3.11: Concentración de clorofila de las muestras estudiadas, frente a el área de las bandas de absorción a diferentes concentraciones. De Izquierda a derecha, pico máximo de absorción situado a 448, 495 y 690 nm respectivamente.

Los coeficientes de correlación obtenidos en el análisis de las distintas bandas de absorción, nos indican que es la última banda, situada aproximadamente en $\lambda = 690 \text{ nm}$, la que aporta una información más precisa acerca de la concentración de clorofila presente en la muestra.

3.3. Conclusiones

La Ley de Beer-Lambert nos ha permitido estudiar las propiedades ópticas del agua y su dependencia con las variables ópticamente activas (OAC) mediante los espectros de absorción, caracterizando el producido por diferentes muestras de agua con diferentes concentraciones de clorofila.

La clorofila presenta dos zonas diferentes de absorción, en los extremos del espectro electromagnético visible, la primera cerca de 450 nm (banda del azul) y la segunda aproximadamente en 690 nm (banda del rojo). Estos picos de absorción incluyen contribuciones de diferentes tipos de clorofila, como son la clorofila-a y la clorofila-b.

Al analizar la resolución espectral de los satélites Sentinel-2 y Landsat 8 en función de los espectros analizados, podemos ver que, si bien las 4 primeras bandas de ambos satélites están centradas en zonas sensibles de estos espectros, midiendo zonas de máximos o mínimos de absorción, es el Sentinel-2, el cual tiene 3 bandas más que Landsat 8, el que nos puede aportar información más precisa sobre la concentración de clorofila presente en el agua.

Por otro lado, vemos que los espectros producidos por las diluciones con diferentes concentraciones de clorofila, asociadas a los diferentes niveles tróficos establecidos por la OCDE son en principio diferenciables entre ellos. Además, podemos ver como las tres bandas de absorción decrecen en amplitud y tamaño conforme decrece la concentración de clorofila de la muestra.

Aislar correctamente las diferentes bandas de absorción, y analizarlas por separado nos permite determinar que es la banda de absorción situada aproximadamente en 690 nm la que aporta una información más relevante acerca de la concentración de clorofila presente en la muestra.

Capítulo 4

Preprocesado de imágenes

4.1. Fusión de imágenes

En la teledetección espacial actual, varios de los satélites multiespectrales ampliamente utilizados, MODIS, VIIRS, ASTER, Worldview-3 y Sentinel-2, Landsat 8, etc. están compuestos de distintos tipos de sensores, entre los que se encuentra uno pancromático (PAN) y otro multiespectral (MS), que registran múltiples bandas espectrales. El sensor multiespectral toma medidas de varias bandas estrechas de menor resolución espacial, mientras que el sensor pancromático mide por lo general una única banda espectral ancha, de menor resolución espectral, pero con mayor resolución espacial. Tales instrumentos tienen la ventaja de que las diferentes bandas espectrales se registran (cuasi) simultáneamente, por lo que la iluminación y las condiciones atmosféricas son similares, sin cambios multitemporales.

Las resoluciones entre las bandas espectrales de cualquier instrumento individual pueden diferir hasta un factor seis aproximadamente, y las razones por las que se toman las bandas con una resolución espacial variable incluyen restricciones de ancho de banda de almacenamiento y transmisión, mejor relación señal-ruido en algunas bandas gracias al uso de píxeles más grandes, bandas diseñadas para propósitos específicos que no requieren alta resolución espacial, etc. Aún así, a menudo se desea homogeneizar las bandas disponibles a una resolución espacial más alta, esto se consigue mediante las técnicas computacionales denominadas fusión de imágenes.

Las técnicas de fusión de imágenes (figura 4.1) hacen referencia, por tanto, a los algoritmos empleados para integrar información de múltiples imágenes con el objetivo de crear una composición que contenga mayor contenido de información que las imágenes originales. En este caso concreto, integrar el detalle espacial de una imagen pancromática y la información espectral de imágenes multiespectral para producir una nueva imagen que combina la alta resolución espacial de la PAN con la alta resolución espectral de la MS.

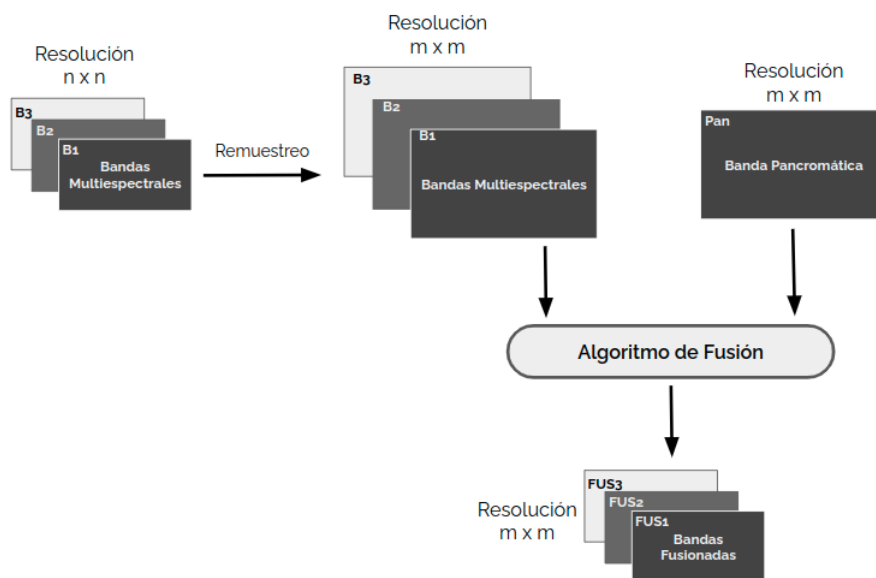


Figura 4.1: Diagrama del proceso de fusión entre las bandas MS y PAN. Adaptada de [79].

Debido a que la comunidad científica ha puesto en los últimos años una gran atención en estas técnicas, los algoritmos de fusión han evolucionado desde simples combinaciones lineales hasta métodos mucho más complejos basados en el análisis de componentes principales o en la transformada wavelet.

La gran variedad de algoritmos de fusión existentes ha dado lugar a diferentes formas de clasificar dichos métodos [80, 81, 82], pero atendiendo a los detalles de su implementación y a su funcionamiento, se pueden resumir dentro de los siguientes grupos:

- **Algoritmos basados en sustitución de componentes:** Estos métodos se basan en aplicar una transformación de las componentes de la imagen MS original, con el objetivo de aislar la información espacial de la imágenes en una de las nuevas componentes de dicha transformación. De esta forma, al sustituir después dicha componente espacial por la imagen PAN y realizar la operación de transformación inversa, se consigue una imagen fusionada de alta resolución espectral y espacial. Ejemplos: Algoritmo de Intensidad-matiz-saturación (IHS) [83, 84], Análisis de Componentes Principales (PCA), etc.
- **Algoritmos basados en operaciones aritméticas:** Las imágenes fusionadas se obtienen como resultado de operaciones algebraicas realizadas entre bandas de la imagen MS y la PAN. Son algoritmos bastante rápidos y sencillos de implementar que, por lo general, permiten fusionar todas las bandas de forma simultánea. Ejemplos: Algoritmos de Brovey, Fast IHS, etc.
- **Algoritmos basados en la inyección de altas frecuencias:** Estos métodos extraen las componentes de alta frecuencia (los detalles) de la imagen PAN, y los “inyectan” en la imagen MS. Ejemplos: Filtro de paso alto (High Pass Filter, HPF).
- **Algoritmos basados en el análisis multiresolución:** Estos métodos más complejos que los anteriores descomponen las bandas MS y PAN en diferentes escalas o resoluciones para extraer los detalles espaciales para después importarlos en las bandas MS a la escala más fina. Ejemplos: transformada wavelet discreta.

En los inicios de la fusión de imágenes, el bajo coste computacional que presentan los algoritmos basados en operaciones aritméticas y los basados en la sustitución de componentes, hizo que estos métodos fueran muy populares y extendidos. Sin embargo, estos proporcionan imágenes fusionadas de menor coherencia espectral, es decir, el color de la imagen fusionada presenta distorsiones respecto al color de las imágenes multispectrales originales. Entre estos métodos podemos destacar el algoritmo de Brovey o la transformada IHS.

Estas limitaciones espectrales de las técnicas anteriores, hizo que surgieran las técnicas que inyectan la información de alta frecuencia y los métodos que utilizan el análisis multirresolución. Entre estas técnicas podemos destacar algoritmos como los métodos HPF [85] y los algoritmos de la Transformada Wavelet Discreta [86, 87]. Las últimas líneas de investigación en este campo pasan por emplear algoritmos de deep learning como las redes neuronales convolucionales [88, 89].

En este trabajo enfrentamos los métodos de fusión tradicionales, a los últimos métodos desarrollados. Se ha implementado para ello un algoritmo de cada uno de los tipos anteriormente detallados, y se han fusionado imágenes de los satélites Sentinel-2 y Landsat 8, comparando los resultados obtenidos. A continuación se detalla el método de fusión utilizado en este estudio, fusión por redes neuronales convolucionales [89], mientras que en el Anexo A se pueden encontrar todos los demás métodos de fusión implementados.

4.1.1. Algoritmos de Fusión

Redes Neuronales Convolucionales

Aunque el lanzamiento del satélite Sentinel-2 y la publicación de los datos en abierto es relativamente reciente en el tiempo, junio de 2015, ya se han publicado estudios que aplican las últimas técnicas de machine learning, las redes neuronales convolucionales (CNN), en la fusión de imágenes de teledetección [88, 89].

Este tipo de algoritmos se basan en el supuesto principal, de que la correlación espectral de la textura de la imagen es similar en un rango (limitado) de escalas. Es decir, que el aumento de muestreo de 20 m a 10 m de resolución espacial, mediante la transferencia de detalles de alta resolución (10 m) a través de bandas espectrales, se puede aprender a partir de imágenes reales y del muestreo de 40 m a 20 m de resolución; de manera similar esto se aplica para el caso de 60 m a 10 m, a partir del muestreo de 360 m a 60 m.

En este trabajo se ha optado por la técnica propuesta en [89], la cual se basa en entrenar una red neuronal convolucional de última generación, llamada DSEN2, para realizar la fusión y llevar las bandas de 20 m a 10 m y otra para las de 60 m a 10 m. Dado que el código original se encuentra en abierto en GitHub, se ha utilizado la misma arquitectura que la red DSEN2.

A continuación se describen los detalles de este método.

- Arquitectura

El diseño de la red DSEN2 [89] utilizada en este trabajo se inspiró en la red EDSR (Red mejorada de residuos profundos para una sola imagen de superresolución) [90]. EDSR sigue la conocida arquitectura ResNet [91] para la clasificación de imágenes, que permite el uso de redes neuronales muy profundas mediante las llamadas “conexiones de salto”.

Sin embargo, el problema planteado es diferente al problema de la super-resolución clásica de una sola imagen, ya que en este caso la red no necesita predecir cómo será la textura de la nueva imagen de alta resolución únicamente sobre la base de imágenes vistas previamente. Más bien, tiene acceso a las bandas de alta resolución para guiar la super-resolución, es decir, debe aprender a transferir el contenido de alta frecuencia a las bandas de baja resolución.

La arquitectura de red propuesta (figura 4.2) consta principalmente de capas convolucionales, ReLU no lineales y conexiones de salto.

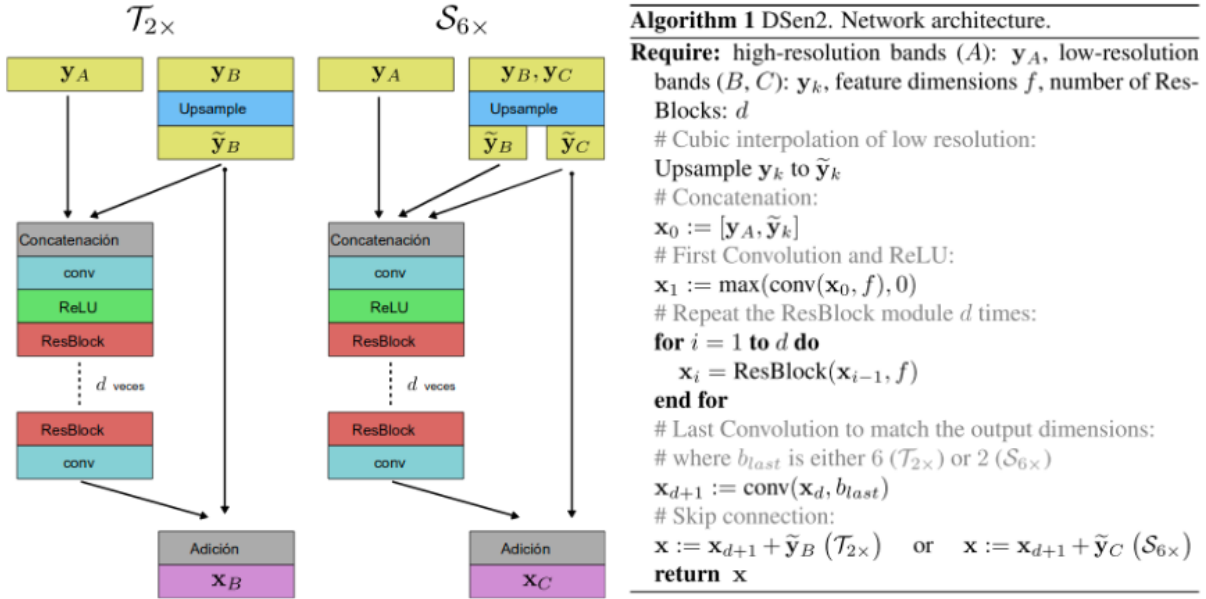


Figura 4.2: Arquitectura y pseudocódigo de las redes neuronales utilizadas. \mathcal{T}_{2x} se refiere a la red utilizada para las bandas de 20 m, mientras que \mathcal{S}_{6x} a la red utilizada para las bandas de 60 m. La diferencia entre ambas arquitecturas se limita a las bandas de entrada utilizadas [89].

Como se ve en el esquema y en el pseudocódigo, el primer paso es el remuestreo de las bandas de baja resolución a la resolución objetivo, la mayor resolución espacial de las bandas disponibles. Este remuestreo se hace mediante una interpolación bilineal simple.

El resto de la red consta principalmente de operadores tales como:

- El operador $\text{conv}(x, f_{out})$, que representa una sola capa de convolución, es decir, una convolución multidimensional de la imagen z con un kernel w , seguida de un sesgo aditivo b :

$$v = \text{conv}(x, f_{out}) := w * z + b$$

$$w : (f_{out} \times f_{in} \times \kappa \times \kappa) \quad , \quad b : (f_{out} \times 1 \times 1 \times 1) \quad (4.1)$$

$$z : (f_{in} \times \omega \times h) \quad , \quad v : (f_{out} \times \omega \times h)$$

donde $*$ es el operador de convolución. Los núcleos de convolución ω tienen dimensiones $k \times k$. Se suele utilizar $k = 3$, de acuerdo con la literatura reciente.

- La unidad lineal rectificada (ReLU) es una función no lineal simple que trunca todas las respuestas negativas en la salida a 0:

$$v = \max(z, 0) \quad (4.2)$$

- Un bloque residual $v = \text{ResBlock}(z, f)$ se define como una serie de capas que operan en una imagen de entrada z para generar una salida z_4 :

$$\begin{aligned} z_1 &= \text{conv}(z, f) \quad , \quad \text{convolución} \\ z_2 &= \max(z_1, 0) \quad , \quad \text{Capa Relu} \\ z_3 &= \text{conv}(z_2, f) \quad , \quad \text{convolución} \\ z_4 &= \lambda \cdot z_3 \quad , \quad \text{residual} \\ v &= z_4 + z \quad , \quad \text{omitir conexión} \end{aligned} \quad (4.3)$$

donde λ es una capa personalizada que multiplica la entrada activa con una constante.

El tamaño y la capacidad adecuados para la red, es siempre una decisión complicada. En este caso se usa $d = 6$ y $f = 128$, correspondiente con 14 capas convolucionales y 1,8 millones de pesos sintonizables. Cada red se implementa en el marco de programación Keras, con TensorFlow como back-end.

■ Datos

Dado que las redes neuronales se enmarcan dentro del aprendizaje supervisado, estas necesitan de una gran cantidad de datos de entrenamiento. Esto es, imágenes para las que se conocen tanto la entrada, bandas de baja resolución espacial, como la salida, de alta resolución, con las que aprender. Por lo tanto, un tema central en este enfoque es cómo construir los conjuntos de datos de entrenamiento, validación y test, dado que las bandas son tomadas a una resolución espacial, y no se dispone de bandas reales sobre el terreno con una resolución de 10 m, para las bandas tomadas a 20 m y 60 m.

El enfoque para crear los datos se basa en el supuesto de que la transferencia de detalles espaciales de bandas de alta resolución a bandas de baja resolución, es invariante en escala y solo depende de la diferencia de resolución relativa entre bandas, pero no de la resolución absoluta de estas. Es decir, las relaciones entre bandas de diferentes resoluciones son similares dentro de un rango de escala relevante. Esta invariancia de escala significa que las asignaciones entre, digamos, $20 \rightarrow 10$ m y $40 \rightarrow 20$ m son aproximadamente equivalentes. Por lo tanto, podemos entrenar a nuestra red en estas últimas, y aplicarlo después a las primeras. Si se mantiene la invariancia asumida, las correlaciones espacio-espectrales aprendidas serán correctas.

Bajo esta suposición, la creación de datos de entrenamiento para el aprendizaje supervisado es simple, solo necesitamos reducir las imágenes originales por el factor deseado, y usar la versión reducida como entrada para generar datos originales como salida.

De este modo, tenemos dos tipos de datos diferentes para cada red. El primero consta de imágenes de “baja resolución”, los datos de entrada, y el segundo de imágenes de “alta resolución”, los datos de salida.

Si aplicamos esto al satélite Sentinel-2, este ofrece imágenes multiespectrales compuestas de 13 bandas espectrales a 3 resoluciones diferentes: 10, 20 y 60 m. En este caso serían necesarias dos redes, una para realizar la fusión de las bandas de 20 m a 10 m y otra para las de 60 m a 10 m. Los conjunto de datos quedarían por tanto: un primer conjunto, para la primera red, con imágenes de “alta resolución” a 20 m e imágenes de “baja resolución” a 40 m, creadas reduciendo la resolución de las bandas originales de 10 y de 20 m respectivamente, en un factor 2. El segundo consta de imágenes con 60, 120 y 360 m, reducido de los datos originales de 10 , 20 y 60 m.

Para el caso de Landsat 8, el satélite solo toma bandas espectrales a resoluciones de 15 y 30 m, por lo que el conjunto de datos es más simple y está compuesto de: imágenes de “alta resolución” a 30 m e imágenes de “baja resolución” a 60 m, creadas reduciendo la resolución de las bandas originales de 15 y 30 m en un factor 2.

- Detalles de entrenamiento

Como función de pérdida se usa el error medio absoluto (L_1) entre el píxel de la imagen de alta resolución verdadera y la predicha. Curiosamente, encontramos que la función de pérdida L_1 converge más rápido y ofrecer mejores resultados que L_2 (error cuadrático medio), aunque este último sirve como métrica de error durante la evaluación. Lo más probable es que esto se deba a que L_1 presenta mayor robustez de la norma ante desviaciones absolutas a valores atípicos. Observamos que algunas imágenes de Sentinel-2 contienen una pequeña cantidad de píxeles con una reflectancia muy alta, y debido al alto rango dinámico estos alcanzan valores extremos sin saturar.

4.1.2. Evaluación de los algoritmos de fusión de imágenes

La forma de evaluar de manera efectiva la calidad de la fusión de imágenes ha sido siempre un desafío. Los algoritmos de fusión buscan controlar el compromiso entre la resolución espectral y espacial de las imágenes. Es decir, las imágenes fusionadas tienen que mejorar la calidad espacial, sin perder la coherencia espectral ni modificar la información original de las imágenes MS.

Es por ello que evaluar la calidad espectral de las imágenes fusionadas no es una tarea fácil. La mayoría de los trabajos publicados en esta línea tienden a centrarse en dos categorías principales de evaluación [86]:

1. Enfoques cualitativos que comparan de forma visual el color y el detalle espacial de las imágenes fusionadas con las imágenes multiespectrales y pancromática originales.
2. Enfoques cuantitativos mediante indicadores de calidad que evalúan las similitudes espectrales y espaciales entre las imágenes.

En este trabajo también se han considerado estos dos enfoques, y se han evaluado las imágenes fusionadas mediante los siguientes indicadores:

1. Una evaluación cualitativa, que consiste en una comparación visual de varios mosaicos creados a partir de imágenes originales y fusionadas.
2. Una evaluación cuantitativa de las imágenes mediante índices de calidad espectral y espacial ampliamente utilizados.

Los índices escogidos para evaluar la calidad espectral y espacial de las imágenes fueron los coeficientes ERGAS espectral y espacial respectivamente. Se puede encontrar una descripción de los índices utilizados en el Anexo-B.

Dado que el objetivo principal es evaluar la precisión de los resultados obtenidos mediante la fusión con redes neuronales y compararlos con los obtenidos mediante los algoritmos antes mencionados, para este apartado se ha implementado un método de cada una de las clases antes expuestas en el apartado [4.1.1](#). De este modo, no solo realizaremos una evaluación de las imágenes mediante los estándares de calidad comúnmente utilizados, sino que además podemos comparar este modelo frente a otros tradicionalmente utilizados. Los métodos escogidos para la comparación fueron: IHS, Brovey, HPF y Transformada Wavelet IHS; y puede encontrarse una descripción de cada uno de ellos en el Anexo-A.

Este análisis se ha realizado tanto para imágenes del satélite Sentinel-2 como para imágenes del satélite Landsat 8, sin embargo, una vez presentado el algoritmo y los resultados para Sentinel-2, los resultados obtenidos para Landsat 8 se pueden encontrar en el Anexo-C.

Sentinel-2

Según lo expuesto en la tabla [1.1](#), las imágenes tomadas por el satélite Sentinel-2 constan de 13 bandas espectrales divididas en 3 resoluciones espaciales diferentes: 10 m (bandas 2-4 y 8), 20 m (bandas 5-7, 8A, 11 y 12) y 60 m (bandas 1, 9 y 10). Esta novedosa distribución, muy beneficiosa para calcular ciertos índices de vegetación, tomando 4 bandas a alta resolución espacial, plantea sin embargo el problema de que el satélite carece de una banda pancromática específica a utilizar en la fusión de imágenes, y esta no se puede realizar según los métodos tradicionales sin determinar qué banda es la más adecuada en cada caso. La fusión de imágenes en el satélite Sentinel-2 requiere, por tanto, de un estudio previo en el cual se determine la banda pancromática a utilizar en cada caso, para la fusión mediante los métodos tradicionales.

Desde la publicación y distribución de las primeras imágenes, se han realizado varios estudios para determinar o producir dicha banda pancromática que falta en el conjunto de datos de Sentinel-2. Varios estudios [\[92, 93\]](#) han comparado tres métodos diferentes para producir una banda pancromática a partir de otras bandas originales tomadas por Sentinel-2. El primer método consiste en producir la banda pancromática promediando todas las bandas de 10 m (banda 2-4 y banda 8), en el segundo método se utilizó el promedio de la banda 4 y la banda 8 (rojo y NIR) para reducir la escala de la banda 5-7, y la banda 8 para reducir la escala de la banda 8A, 11 y 12 y en el tercer método utilizado se determinó la banda adecuada en cada caso, mediante la correlación lineal, y se usó la banda 4 para la banda 5, 11 y 12, y la banda 8 para la banda 6, 7 y 8A.

Las conclusiones obtenidas en estos estudios fueron que, si bien todas las bandas pancromáticas utilizadas obtenían resultados precisos en la fusión de imágenes, el primer método, utilizar el promedio de todas las bandas de 10 m, obtenía los mejores resultados en dos de cada tres casos de uso. Basándonos en estas conclusiones, en este trabajo se ha decidido seguir el mismo criterio, y utilizar en todos los casos, el promedio de todas las bandas de 10 m de resolución como banda pancromática.

Cabe mencionar que cada tipo de fusión utilizado depende de una serie de parámetros los cuales han tratado de ser optimizados y detallados en la medida de lo posible, de forma que los resultados puedan ser interpretados y extrapolados para la fusión de cualquier otra imagen. De hecho, el estudio completo se ha realizado para cinco imágenes diferentes, de cinco países diferentes, que representan distintos tipos de superficies terrestres. Las imágenes que se utilizaron son las que se muestran en la figura siguiente:

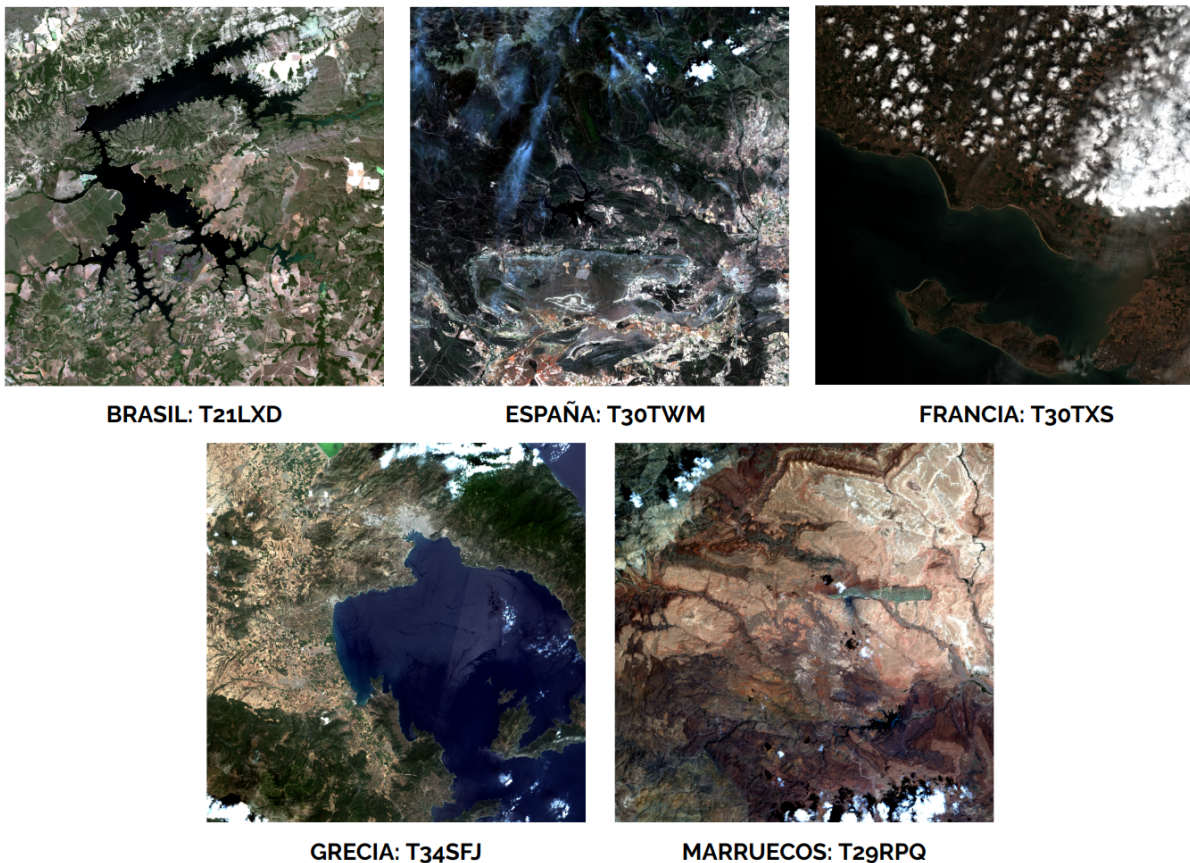


Figura 4.3: Imágenes del satélite Sentinel-2 utilizadas en las evaluaciones cualitativa y cuantitativa de los métodos de fusión analizados.

- Evaluación Cualitativa

La evaluación cualitativa consiste en una comparación visual de las imágenes, por lo que en este apartado se mostrarán las bandas MS originales frente a las fusionadas, y se evaluará el resultado.

Durante el análisis se pretenden valorar criterios muy diferentes tales como el color y el aspecto de las imágenes, el detalle espacial y la nitidez de los bordes, etc. Es preciso señalar que este tipo de evaluación puede contener un factor subjetivo que hace difícil que dos observadores coincidan exactamente en las interpretaciones.

Para el análisis se han elaborado varios mosaicos (figuras 4.4 a 4.9) que contienen imágenes completas de las bandas, histogramas calculados a partir de los valores de los píxeles y regiones específicas de la imagen, resaltadas para mostrar más nítidamente el detalle espacial de las imágenes con el objetivo de facilitar el análisis visual. Todos los mosaicos están compuestos por las bandas en su versión original, así como las imágenes tratadas mediante los métodos de fusión: IHS, Brovey, HPF, Transformada Wavelet IHS y CNN.

Sin embargo, el espacio que ocuparían los mosaicos de todas las bandas MS de las cinco regiones diferentes, imposibilita incorporar en esta evaluación todas las bandas analizadas, por lo que en este apartado solo se han incluido algunas de las bandas más representativas de una de las regiones evaluadas. La imagen mostrada se corresponde con la zona geográfica T21LXD de Brasil, según el sistema de coordenadas UTM (Universal Transversa de Mercator).

Las primeras figuras (4.4 a 4.7) tratan de mostrar la coherencia espectral que las bandas fusionadas mantienen con las bandas originales, es decir, las diferencias de color que se hayan podido producir en la imagen durante el proceso de fusión. Se muestran por tanto, las bandas originales y las fusionadas en las cuales se han marcado las zonas de la imagen con mayor diferencia espectral, o lo que es lo mismo, las zonas que han sufrido un mayor cambio en el color durante el proceso de fusión. También se muestran en estas imágenes los histogramas producidos al restar la banda original de la banda fusionada CNN, y la banda original de la banda fusionada TRWH (Transformada Wavelet IHS), es decir, las distribuciones de las diferencias entre bandas para los dos métodos que obtuvieron los mejores resultados.

Al igual que los datos originales proporcionados por la ESA, todas las bandas se encuentran escaladas a enteros de 16 bits, 2^{16} niveles de gris. En las imágenes de los mosaicos se han marcado en color blanco todos los píxeles encontrados con una diferencia superior a 750 niveles digitales.





Figura 4.4: Banda 5 del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.

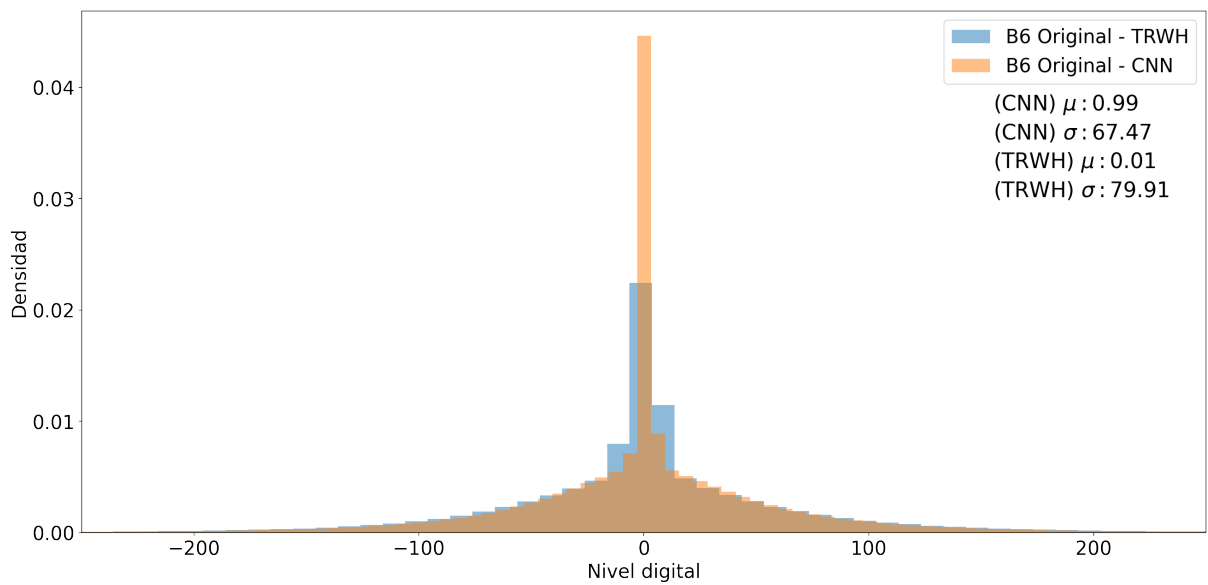



Figura 4.5: Banda 6 del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.





Figura 4.6: Banda 7 del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.





Figura 4.7: Banda 8 del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.

Como se puede ver en las imágenes [4.4](#) a [4.7](#), los métodos Brovey y HPF, son los que más han cambiado el aspecto original de las bandas MS durante la fusión. Estas bandas presentan un aspecto más oscurecido que las originales, lo cual podría deberse a una pérdida o disminución del contraste durante el proceso.

Por su parte, el método de transformada de wavelet y el método basado en CNN son los que mejor han mantenido el aspecto de las bandas originales, y no se aprecia ningún cambio significativo en la tonalidad de la imagen. Los histogramas confirman los buenos resultados obtenidos por el método CNN, manteniendo la distribución de la diferencia entre bandas centrada en cero y con una desviación estándar inferior a 350 niveles digitales para todas las bandas.

Si bien en la sección anterior se pretendían reflejar los cambios producidos en el aspecto y en el color de las bandas, ahora (figuras [4.8](#) y [4.9](#)) se pretende destacar la calidad espacial que las bandas fusionadas han obtenido durante el proceso. Se muestra por ello una pequeña área destacada de una imagen completa, con la intención de resaltar la nitidez de los detalles y de los bordes en ese área.




Figura 4.8: Área destacada de las bandas 5 y 6 (de 20 m de resolución) frente a las imágenes obtenidas mediante los distintos métodos de fusión (10 m de resolución). Arriba, de izq a dch: banda original, fusión Brovey, HPF. Abajo, de izq a dch: IHS, Wavelet (TRWH) y CNN.




Figura 4.9: Área destacada de las bandas 7 y 8A (de 20 m de resolución) frente a las imágenes obtenidas mediante los distintos métodos de fusión (10 m de resolución). Arriba, de izq a dch: banda original, fusión Brovey, HPF. Abajo, de izq a dch: IHS, Wavelet (TRWH) y CNN.

En lo referente a la calidad espacial, si bien todos los métodos proporcionan resultados satisfactorios, ya que todas las imágenes han mejorado su calidad espacial con respecto a la banda original, la fusión mediante redes neuronales proporciona unos resultados cualitativamente mejores que los métodos Brovey y HPF, ya que las imágenes parecen más realistas y naturales. La mejora con respecto a los métodos IHS y wavelet aditivo no es tan acusada.

- Evaluación Cuantitativa

La evaluación cuantitativa de las imágenes se ha realizado mediante los coeficientes de calidad expuestos en el Anexo-B. Se han utilizado coeficientes diseñados tanto para evaluar la calidad espectral como la calidad espacial de las imágenes, por lo que la combinación de estos nos da una idea global de todos los detalles que influyen en el resultado final de la fusión.

Cabe destacar que, para poder realizar este análisis y poder comparar las imágenes originales con las fusionadas, es necesario degradar la calidad las imágenes originales, de modo que al realizar el proceso de fusión, la resolución de las nuevas imágenes sea la misma que las de las imágenes originales. Se han degradado por tanto las imágenes multiespectrales de 20 m y la banda pancromática de 10 m a un resolución de 40 y 20 m respectivamente. Las degradaciones de las imágenes se realizó aplicando un filtro binomial.

Los filtros binomiales se generan a partir de la función binomial la cual está definida de la siguiente manera:

$$f_N(x) = \binom{N}{x} = \frac{N!}{x!(N-x)!} \quad (4.4)$$

Los filtros binomiales en 2 dimensiones se obtienen de la siguiente manera:

$$[f_N(x)]^T \times [f_N(x)] \quad (4.5)$$

y para el caso del filtro de orden N=2 tendríamos:

$$\begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \times \begin{bmatrix} 1 & 2 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (4.6)$$

Además, como ya se comentó en el apartado anterior, y para probar que los resultados obtenidos se pueden extrapolar a cualquier otra imagen, este estudio también se ha realizado para cinco imágenes diferentes, de cinco zonas diferentes. Los resultados presentados en las distintas tablas representan la media de los datos obtenidos para las cinco imágenes.

Las pequeñas diferencias obtenidas en los resultados de los diferentes métodos y bandas, nos ha llevado a mostrar los datos con tres cifras significativas de precisión con el fin de poder comparar mejor los resultados obtenidos.

– ERGAS espectral

El coeficiente ERGAS tiene una fuerte tendencia a decrecer cuando la calidad de la imagen fusionada es buena. Valores menores que 3 expresan una buena calidad de la fusión, que será mejor cuanto más cercano sea a cero.

Banda	IHS	Brovoy	HPF	TRWH	CNN
B5	6.743	10.119	6.381	2.106	1.375
B6	5.097	8.408	5.103	1.732	1.131
B7	4.546	8.079	4.934	1.692	1.154
B8A	4.674	7.884	4.833	1.648	1.126
B11	5.724	7.735	5.245	1.683	1.497
B12	7.223	8.516	6.088	2.437	2.132

Tabla 4.1: Valores obtenidos en el análisis Ergas espectral según los distintos métodos de fusión empleados.

Los valores extraídos del coeficiente ERGAS espectral no hacen sino confirmar la valoración que ya habíamos realizado en el apartado de análisis cualitativo, y es que los métodos IHS, Brovey y HPF son los que peores resultados ofrecen. Por lo general, los resultados obtenidos por estos métodos no se alejan mucho del 3, valor que representaría una buena calidad en la fusión, pero los resultados no son satisfactorios.

Los resultados de los métodos de transformada de Wavelet y CNN son sin embargo muy buenos, manteniendo valores más bajos que 3, incluso en muchas ocasiones muy cercanos a 1, en todas las bandas fusionadas. El método que mejores resultados ofrece es el método de fusión mediante redes neuronales convolucionales, si bien la diferencia con el modelo de transformada de wavelet no es sustancialmente importante.

– ERGAS espacial

El coeficiente ERGAS espacial es uno de los indicadores especializados en medir la calidad espacial de las imágenes fusionadas. Al igual que en el caso del ERGAS espectral tiene una fuerte tendencia a decrecer cuando la calidad de la imagen fusionada es buena. Valores alrededor de 3 expresan una buena calidad de la fusión, que será mejor cuanto más cercano a cero sea.

Banda	IHS	Brovey	HPF	TRWH	CNN
B5	8.266	8.054	7.122	4.546	4.658
B6	1.625	4.510	7.681	6.144	6.519
B7	4.040	5.071	9.119	8.081	8.471
B8A	4.668	5.289	9.821	8.983	9.355
B11	7.357	8.160	13.301	12.767	13.195
B12	9.624	12.252	16.306	15.712	16.390

Tabla 4.2: Valores obtenidos para el coeficiente Ergas espacial según los distintos métodos de fusión empleados.

Si bien los resultados obtenidos mediante este indicador no parecen buenos para ninguno de los métodos empleados, podemos separar claramente los resultados obtenidos para las bandas 11 y 12, bandas situadas en el espectro en la franja del infrarrojo de onda corta (SWIR), de los obtenidos para las bandas 5, 6, 7 y 8A, situadas en la zona del infrarrojo cercano (NIR).

Los valores obtenidos para las bandas 11 y 12 son claramente más elevados que los de el resto de el resto de bandas, las cuales si bien tampoco obtienen calificaciones próximas a 0 (indicador de muy buena calidad), varios de los valores obtenidos si están próximos al 3 que indicaría una buena calidad espacial en la fusión.

Para este apartado hay que mencionar que la banda pancromática utilizada para calcular los resultados, es la misma que se ha utilizado en los procesos de fusión, el promedio de todas las bandas de 10 m. Este planteamiento es correcto para todos los métodos tradicionales utilizados, pero no lo es para el método de fusión mediante redes neuronales, ya que realmente no conocemos la banda pancromática utilizada por la red.

El modelo de fusión por redes neuronales, la red dispone de todas las bandas espectrales tanto de 10 como de 20 m, y calcula el resultado final mediante combinaciones de todas ellas, pero no sabemos qué banda utiliza como banda pancromática o si utiliza siquiera una banda pancromática como tal. Lo que sabemos es que calcula el valor de los píxeles a predecir, en función de todas las demás bandas, y del valor original.

4.1.3. Conclusiones

Las nuevas técnicas de pansharpening o fusión de imágenes: la transformada de wavelet aditivo por IHS o las redes neuronales convolucionales requieren de más capacidad de cálculo a la hora de realizar los procesos de la fusión, pero obtienen mejores resultados que los métodos utilizados tradicionalmente: IHS, Brovey o HPF.

El algoritmo de fusión por redes neuronales es el método que mejores resultados ha obtenido de los cinco métodos evaluados en la parte de evaluación espectral. Este algoritmo obtiene mejores resultados en el coeficiente ERGAS espectral, que evalúa la calidad espectral de las imágenes, lo que indica que este método es el ideal cuando se necesita que la coherencia espectral se mantenga casi inalterada entre la banda original y la banda fusionada. Este punto es muy importante a la hora de calcular índices espectrales o cuando tratamos de estimar alguna variable derivada de los datos satelitales, ya que distorsionar el valor de reflexión de la banda puede influir y distorsionar el valor del parámetro que queremos calcular.

4.2. Corrección atmosférica

La corrección atmosférica constituye una de las partes más importantes del preprocesamiento de los datos obtenidos en teledetección, y su objetivo es determinar el valor real de reflectancia de la superficie de la Tierra, a partir de la reflectancia aparente medida por el sensor.

Los fenómenos de absorción y difusión de la luz producidos por la atmósfera, provocan una importante variación en los valores de reflectividad que los canales multispectrales obtienen en la parte superior de la atmósfera (TOA). De hecho, debido a la baja reflectividad del agua, la influencia de la atmósfera sobre la reflectividad recibida por el satélite se convierte en la fuente mayoritaria debido al fenómeno de retrodifusión de la luz, siendo en los canales cercanos al rojo donde, por la mayor absorción del agua, la contribución atmosférica puede superar el 90 % de la reflectividad total.

Además, y dado que el camino óptico no es el mismo para la radiación ascendente y la descendente, la influencia atmosférica no afecta por igual a las dos componentes del cálculo de la reflectividad. En definitiva, la reflectividad que capta el sensor no es igual a la emitida por la superficie.

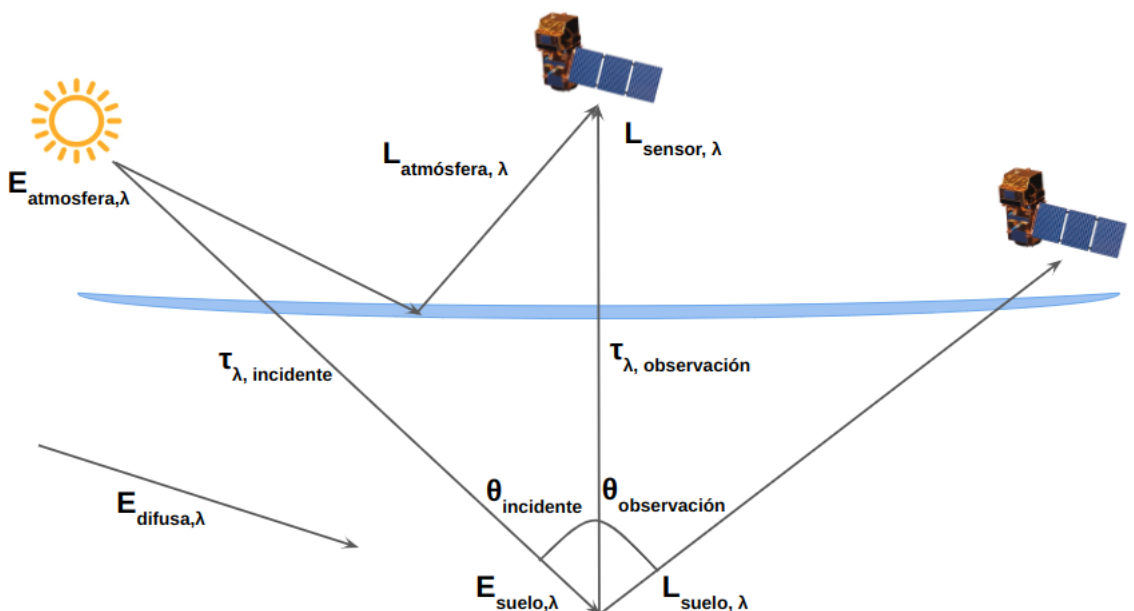


Figura 4.10: Esquema del efecto que produce la atmósfera en al radiación solar detectada por los sensores. Adaptada de [94].

La ecuación para determinar correctamente la radiación reflejada por la superficie, sin tener en cuenta la influencia atmosférica [95]:

$$L_{sensor,\lambda} = L_{suelo,\lambda} \cdot \tau_{\lambda,observación} + L_{atmósfera,\lambda} \quad (4.7)$$

Donde $L_{sensor,\lambda}$ es la radiación que recibe el sensor, $L_{suelo,\lambda}$ la radiancia que sale de la superficie, $\tau_{\lambda,observación}$ la transmisividad de la atmósfera para el flujo ascendente (o transmisividad para la radiancia observada), y $L_{atmósfera,\lambda}$ la radiancia aportada por la dispersión atmosférica.

Para considerar correctamente la influencia atmosférica sobre el flujo de energía ascendente, la transmisividad en la dirección ascendente ($\tau_{\lambda,observación}$, transmisividad que aparece en la ecuación anterior), depende del espesor óptico del ozono ($\tau_{ozono,\lambda}$), de los aerosoles ($\tau_{aerosoles,\lambda}$), de las moléculas presentes en la atmósfera ($\tau_{moléculas,\lambda}$), para cada λ de cada banda distinta, y del ángulo de visión ($\theta_{observación}$), y se puede expresar mediante la ecuación:

$$\tau_{\lambda,observación} = e^{\frac{-\tau_{ozono,\lambda} - \tau_{aerosoles,\lambda} - \tau_{moléculas,\lambda}}{\cos\theta_{observación}}} \quad (4.8)$$

Si ahora nos fijamos en el flujo incidente, tampoco la irradiancia que llega a la superficie ($E_{suelo,\lambda}$) es la misma que llega a lo alto de la atmósfera ($E_{atmósfera,\lambda}$). Esta se ve afectada por la atenuación de la atmósfera y por la componente de la luz difusa:

$$E_{suelo,\lambda} = E_{atmósfera,\lambda} \cdot \cos\theta_{incidente} \cdot \tau_{\lambda,incidente} + E_{difusa,\lambda} \quad (4.9)$$

donde $\theta_{incidente}$ es el ángulo cenital del flujo incidente, formado por la vertical y los rayos solares, $\tau_{\lambda,incidente}$ es la transmisividad que afecta al rayo incidente y $E_{difusa,\lambda}$ es la irradiancia difusa, como consecuencia de la dispersión y que depende de las condiciones de la atmósfera. La transmisividad incidente, a diferencia de la ascendente, depende del ángulo de incidencia, $\theta_{incidente}$:

$$\tau_{\lambda,incidente} = e^{\frac{-\tau_{ozono,\lambda} - \tau_{aerosoles,\lambda} - \tau_{moléculas,\lambda}}{\cos\theta_{incidente}}} \quad (4.10)$$

Para llegar finalmente a la ecuación de la reflexión de la superficie (Ec. 4.11), tenemos que tomar la ecuación de la reflexión en el techo de la atmósfera y sustituir todas las expresiones anteriores. Obtenemos por tanto que, la reflectividad de la superficie terrestre puede expresar como:

$$\rho_{\lambda} = \frac{(L_{sensor,\lambda} - L_{atmósfera,\lambda}) \cdot d_{ES}^2 \cdot \pi}{\tau_{\lambda,observación} (E_{atmósfera,\lambda} \cdot \cos\theta_{incidente} \cdot \tau_{\lambda,incidente} + E_{difusa,\lambda})} \quad (4.11)$$

donde d_{ES} la distancia Tierra-Sol en unidades astronómicas.

Para lograr aplicar una corrección atmosférica adecuada, es necesario conocer las condiciones atmosféricas exactas para el momento en el que se tomó la imagen. Además, el efecto atmosférico no es igual en todo el área que cubre la imagen, sino que depende de cada zona y puede afectar de diferentes maneras en unas zonas que otras. Se suele recurrir, por ello, a ciertas simplificaciones o aproximaciones que modelen estos datos.

Tras una revisión exhaustiva del estado del arte, en el siguiente apartado se presentan las técnicas y modelos implementados actualmente para abordar las correcciones atmosféricas.

4.2.1. Algoritmos de corrección atmosféricas

Mediciones in situ con radiómetros hiper-espectrales

El método más preciso para realizar las correcciones, es desplegar en la zona de medida un radiómetro que permita determinar entre otros parámetros, la radiación solar incidente, y la reflectividad del terreno.



Figura 4.11: Imagen de unos radiómetros hiper-espectrales colocados en Doñana para realizar la calibración de los datos de teledetección.

Sabiendo la fecha y hora a la que el sensor va a captar la imagen de la zona de estudio, se pueden tomar medidas in situ de la radiación solar y de la reflectividad de la superficie con las que calibrar después los datos de teledetección medidos. El principal problema de este método es el elevado coste económico, y la elevada dificultad técnica que supone desplegar radiómetros en todas las zonas de monitorización.

Modelos físicos de transferencia radiativa

Estos modelos son capaces de calcular la reflectancia en la superficie a partir de la señal captada por el sensor y de una caracterización atmosférica similar a la correspondiente a la zona y la fecha en la que se capta la imagen. Modelan el comportamiento de la atmósfera, la dispersión y la absorción que produce, para cada longitud de onda teniendo en cuenta los parámetros principales. El problema radica en conocer la composición real de gases en la atmósfera.

Para ello estos modelos cuentan con una serie de patrones atmosféricos representativos de las diferentes condiciones atmosféricas, desde las condiciones más suaves a las más extremas, los cuales logran ser una buena aproximación.

Además, para mejorar la caracterización atmosférica, también cuentan con simulaciones de aerosoles presentes en la atmósfera, los cuales sirven de complemento a las atmósferas estándar. Todo esto hace que estos modelos sean capaces de cubrir una gran variedad de condiciones diferentes, desde el nivel del mar hasta la mesosfera, proporcionando estimaciones de la transferencia radiativa.

Algunos de los modelos de transferencia radiativa más conocidos son el modelo 6S, el modelo FLAASH (Fast Line-of-Sight Atmospheric Analysis), basado en el código de transferencia radiativa MODTRAN, y el modelo ATCOR.

Correcciones a partir de datos presentes en la propia imagen.

Como se ha indicado, obtener la composición de la atmósfera y los coeficientes implicados en el proceso, suele resultar muy complicado o incluso imposible si trabajamos con datos antiguos ya archivados. Por este motivo, existen métodos que hacen uso únicamente de la información procedente de la imagen a tratar, para realizar las correcciones atmosféricas pertinentes. Estos métodos se basan en hipótesis simplificadas, donde por lo general la atmósfera se modela aproximadamente como un difusor de la luz.

Los algoritmos más populares de este tipo son el método DOS (Dark Object Subtraction), y el método COST.

– DOS y COST:

El método DOS, propuesto por Chavez en 1975, y posteriormente mejorado en 1988 y 1996 [96], consiste en la suposición de que las áreas cubiertas con materiales de elevada absorción, agua y zonas de sombra, presentan una reflectividad casi nula y deben representarse por tanto en la imagen con valores de reflectancia iguales o próximos a cero.

Sin embargo, esta suposición no suele ser del todo realista debido precisamente a los fenómenos de dispersión atmosférica (dispersión de Rayleigh y Mie), los cuales proporcionan valores superiores a cero, y mayores cuanto menor es longitud de onda.

El método COST mejora esta suposición del método DOS con el hecho de que muy pocos objetos sobre la superficie terrestre son absolutamente oscuros, y asume que estos suponen el 1% de la reflectancia de la imagen completa. La radiancia de un objeto absolutamente oscuro queda entonces representada como:

$$L_{\lambda}^{sp,1\%} = \frac{0,01 \cdot E_{atm\acute{o}sfera,\lambda} \cdot \cos\theta_{incidente}}{d_{ES}^2 \cdot \pi} \quad (4.12)$$

La radiancia aportada por la dispersión atmosférica, $L_{a,\lambda}$ pueden ser calculada entonces restándole el valor de $L_{\lambda}^{sp,1\%}$, y la reflexión de la atmósfera queda representada por la ecuación:

$$\rho_{\lambda} = \frac{(L_{sensor,\lambda} - (L_{atm\acute{o}sfera,\lambda} - L_{\lambda}^{sp,1\%})) \cdot d_{ES}^2 \cdot \pi}{\tau_{\lambda,observaci\acute{o}n} (E_{atm\acute{o}sfera,\lambda} \cdot \cos\theta_{incidente} \cdot \tau_{\lambda,incidente} + E_{difusa,\lambda})} \quad (4.13)$$

En el método DOS, los coeficientes $\tau_{\lambda,observaci\acute{o}n}$, $\tau_{\lambda,incidente}$ y $E_{difusa,\lambda}$ toman los valores:

$$\begin{aligned} \tau_{\lambda,observaci\acute{o}n} &= 1 \\ \tau_{\lambda,incidente} &= 1 \\ E_{difusa,\lambda} &= 0 \end{aligned} \quad (4.14)$$

Mientras que el método COST propone la aproximación de igualar el efecto multiplicativo de la transmisividad atmosférica que afecta al rayo incidente, $\tau_{\lambda,incidente}$, y la transmisividad de la atmósfera para el flujo ascendente, $\tau_{\lambda,observaci\acute{o}n}$, mediante las siguientes expresiones:

$$\begin{aligned} \tau_{\lambda,incidente} &= e^{-(AOD \cdot \sec\theta_{incidente})} \\ \tau_{\lambda,observaci\acute{o}n} &= e^{-(AOD \cdot \sec\theta_{observaci\acute{o}n})} \end{aligned} \quad (4.15)$$

donde AOD representa el espesor óptico de la atmósfera.

4.2.2. Correcciones atmosféricas aplicadas

Como se ha apuntado anteriormente, y debido a la baja reflectividad del agua, la influencia de la atmósfera sobre la señal recibida en estos casos, se convierte en la fuente mayoritaria que, en función de la longitud de onda, puede incluso superar el 90 % de esta. Además, y mientras que en mar abierto la señal emitida por la superficie del agua y recibida por el satélite sólo está determinada por la concentración del pigmento clorofila-a del fitoplancton, en aguas costeras, estuarios, ríos y aguas continentales, convencionalmente también influyen otras sustancias tales como sedimentos inorgánicos en suspensión y sustancias “amarillas”. En consecuencia, la recuperación cuantitativa de los parámetros de calidad del agua, como la turbidez, depende en gran medida del rendimiento de los algoritmos de corrección atmosférica [97].

El algoritmo utilizado en este trabajo es la versión más actual del software [ACOLITE¹](#), el cual ha demostrado tener un mejor rendimiento que otros procesadores para aguas ricas en sedimentos, y que en 2018 incorporó un nuevo enfoque de corrección atmosférica, el ajuste de espectro oscuro (DSF, Dark Spectrum Fitting).

ACOLITE

ACOLITE reúne los algoritmos de corrección atmosférica y el software de procesamiento desarrollados por el Real Instituto Belga de Ciencias Naturales [98] para aplicaciones acuáticas de datos satelitales con resolución espacial métrica y decamétrica entre los que se encuentran los satélites Landsat (5/7/8) y Sentinel-2 (A/B). Está particularmente desarrollado para el procesamiento de aguas turbias y pequeños cuerpos de agua continentales ya que además de realizar la corrección atmosférica, puede generar varios parámetros derivados de las reflectancias del agua. El último código fuente de ACOLITE Python está disponible en [GitHub²](#).

¹<https://odnature.naturalsciences.be/remsem/software-and-data/acolite>

²<https://github.com/acolite/acolite>

El software incluye dos algoritmos de corrección atmosférica, el algoritmo configurado de forma predeterminada “Dark Spectrum Fitting” o DSF [99] y el antiguo algoritmo de ‘Extrapolación exponencial’ o EXP [98]. Se recomienda el uso de DSF, pero EXP se incluye para completar y para los usuarios y las aplicaciones que dependen de él. ACOLITE cuenta además con la herramienta de corrección atmosférica para bandas térmicas (TACT) [100] y se puede usar para recuperar las temperaturas superficiales de los sensores Landsat. Para ejecutar la herramienta TACT se requiere de alguna configuración adicional, ya que depende de las entradas del perfil atmosférico y libRadtran (ver más adelante).

DSF

El software ACOLITE aplica por defecto el enfoque recomendado de ajuste de espectro oscuro (DSF). Este esquema se basa exclusivamente en datos obtenidos de las imágenes y, por lo tanto, no necesita de entradas externas como el espesor óptico de aerosol ya sea medido o estimado. El algoritmo asume que la atmósfera es homogénea sobre la escena o sub-escena procesada, lo que permite predecir la reflectancia de la trayectoria atmosférica a partir de múltiples objetivos oscuros presentes en la escena. Estos objetivos se seleccionan de acuerdo con los valores más bajos observados de reflectancia en la parte superior de la atmósfera para cada una de las bandas. Es decir, para cada banda, el objeto más oscuro se estima a partir de:

1. El mínimo absoluto.
2. En percentil.
3. El desplazamiento de un ajuste OLS a los primeros mil píxeles del histograma.

y con esto se crea lo que se denomina un espectro oscuro ρ_{dark} . Una vez obtenido este espectro, se elige un modelo de aerosol continental o marítimo en función del RMSE más bajo entre la ρ_{dark} observada y la ρ recuperada para las dos bandas de ajuste más cercanas. Además se implementan dos configuraciones distintas para el algoritmo DSF:

1. Una opción de τ_a fijo, que calcula un solo τ_a para la escena o subescena si a la hora de procesar la imagen se proporcionan coordenadas límites para un ROI.
2. Una opción de τ_a en mosaico, que divide la escena completa en mosaicos de aproximadamente 6x6 km, y recupera τ_a por mosaico e interpola los parámetros atmosféricos recuperados en la escena completa.

Además, el algoritmo DSF cuenta ahora también con una opción de corrección del destello solar. El DSF utiliza las bandas y los píxeles que dan la estimación más baja del espesor óptico del aerosol sobre la región procesada. Esto permite una estimación de la reflectancia de la trayectoria atmosférica que es relativamente insensible al reflejo del sol. Sin embargo, la señal del reflejo del sol seguirá estando presente en la reflectancia de la superficie resultante. Se incluye una opción de corrección del destello solar, que por defecto usa las bandas SWIR para estimar la señal del destello, como en Harmel et al. (2018). La implementación y el desempeño se analizan en Vanhellefont (2019a). Se proporciona una corrección de destello solar alternativa, que estima la reflectancia de destello promedio en un rango de bandas SWIR y extrapola esto a las bandas VNIR utilizando una forma de reflectancia modelada.

Capítulo 5

Monitorización del embalse de “El Val” mediante teledetección

Como se mencionó en el apartado [5.1](#), este estudio se ha centrado en el embalse de El Val, figura [3.1](#), situado en Los Fayos, municipio de la Comarca de Tarazona y el Moncayo, en la provincia de Zaragoza. El estudio encargado por la Confederación Hidrográfica del Ebro y realizado por la PYME Ecohydros en 2017 concluía que el embalse soporta un exceso en la carga de fósforo procedente de los vertidos de las aguas residuales de las poblaciones de Ólvega y Ágreda, tratados en la EDAR de Ágreda, así como de las actividades ganaderas y de la actividad industrial de la zona [\[76\]](#). Además, los informes de seguimiento de calidad de agua de la Confederación Hidrográfica del Ebro de 2018 y 2019 califican al embalse como eutrófico o hipereutrófico ([\[74, 75\]](#)).

En 2019 la CHE encargó a la PYME Ecohydros S.L. la realización de estudios de mayor resolución espacio-temporal con los que acotar los diferentes agentes causales, e implementar soluciones a la eutrofización del agua. Este estudio se enmarca en el contexto de dichos trabajos.



Figura 5.1: Mapa de la península ibérica y posicionamiento geográfico del embalse de “El Val”.

El embalse cuenta desde 2018 con monitorización en continuo mediante una sonda multiparamétrica modelo “Aquadam”, situada en la zona más próxima a la presa, la cual realiza perfiles métricos verticales cada 6 horas (Tabla [5.1](#)) en los que se toman medidas de diferentes parámetros físico-químicos a lo largo de la columna de agua, tales como: temperatura, conductividad, pH, oxígeno disuelto, turbidez, etc, además de otros parámetros biológicos entre los que se encuentra la concentración clorofila.

A continuación se muestra como ejemplo parte de las medidas tomadas durante un perfil realizado por la sonda, el día 30/09/2021. El perfil completo se mostró en la tabla

[3.1](#)

Fecha (hh:mm:ss)	Cota (msnm)	Prof (m)	Temp (°C)	pH	Redox (mV)	Cond ($\mu\text{g}/\text{cm}$)	Ox. disuelto (mg/l)	Turbidez (NTU)	Clorofila-a ($\mu\text{g}/\text{l}$)
14:01:00	606.50	1.05	20.1	8.76	288.0	419.0	8.8	6.3	86.1
14:05:00	605.54	2.02	20.0	8.64	290.0	421.0	7.8	7.6	23.3
14:09:00	604.54	3.02	20.0	8.07	296.0	424.0	5.0	7.9	19.6
14:13:00	603.55	4.01	19.9	7.85	299.0	424.0	4.1	8.0	13.1
14:17:00	602.54	5.01	19.9	7.75	300.0	425.0	3.9	7.9	14.9
14:22:00	601.55	6.01	19.9	7.71	300.0	425.0	3.7	7.9	16.6

Tabla 5.1: Ejemplo de los datos tomados durante el perfil métrico vertical realizado por la sonda “Aquadam” el día 30/09/2021.

Esta sonda se encuentra operativa desde febrero de 2018, y los datos se pueden encontrar en abierto en la página de la [Confederación Hidrográfica del Ebro](#)¹. Estos datos, en abierto, han facilitado la realización del estudio dada la amplia cobertura a lo largo de cuatro años, cubriendo una amplia gama de condiciones tróficas.

Entre las variables medidas por la sonda, los parámetros inicialmente escogidos para comparar la monitorización del estado trófico del embalse mediante teledetección fueron la temperatura, la turbidez y la clorofila; variables ópticamente activas, y por lo tanto aptas para el seguimiento mediante teledetección. Estas son variables esenciales para la supervisión de aguas interiores según el “*Programa Internacional Cooperación sobre la Eutrofización*”, [33], desarrollado en la década de 1970 por la Organización de Cooperación y Desarrollo Económicos para la Supervisión de Aguas Interiores (OCDE, 1982).

En estos informes se otorgan valores límites de concentración de nutrientes (fósforo y nitrógeno), por ser el primer indicador de eutrofización, y también valores límites de concentración de clorofila y de profundidad de disco Secchi, como estimación de la turbidez, para los diferentes niveles tróficos, lo que muestra la importancia de su monitorización.

Los satélites utilizados para la monitorización del embalse han sido los satélites Landsat 8 y Sentinel-2. Las ventajas más evidentes de trabajar con ambos satélites son la cobertura tanto del espectro óptico, como del térmico, además de trabajar con una resolución temporal (o tiempo de revisita) de cinco días.

¹<https://saica.chebro.es/embalsesEV.php>

Las imágenes descargadas y analizadas corresponden a los años 2018, 2019, 2020 y 2021. El tiempo de revisita de los satélites Landsat 8 y Sentinel-2 es de 16 y 5 días respectivamente, y el número de imágenes encontradas para ese periodo son las que se indican en la tabla [5.2](#):

	Landsat 8	Sentinel-2
2018	23	70
2019	22	73
2020	22	72
2021	22	72

Tabla 5.2: Distribución temporal de las imágenes de los satélites Landsat 8 y Sentinel-2 utilizadas.

La tabla anterior muestra el número total de imágenes para cada uno de los satélites, si bien no se han utilizado las imágenes que, o bien por nubes o por cualquier otro problema de calidad, no eran útiles para el trabajo.

La complejidad técnica de los sistemas utilizados en teledetección, la dificultad de trabajar con datos georreferenciados, el volumen de datos disponible actualmente y los diferentes niveles de procesamiento involucrados en la obtención de parámetros geofísicos a partir de imágenes satelitales, requieren el establecimiento de una jerarquía de procesos que permitan la generación de productos operacionales de alto nivel que sean de utilidad tanto para usuarios finales específicos como para la comunidad científica en general.

El diagrama de flujo de los distintos niveles de procesamiento aplicados a los datos satelitales utilizados para la obtención de parámetros geofísicos se puede ver en la figura

[5.2](#)

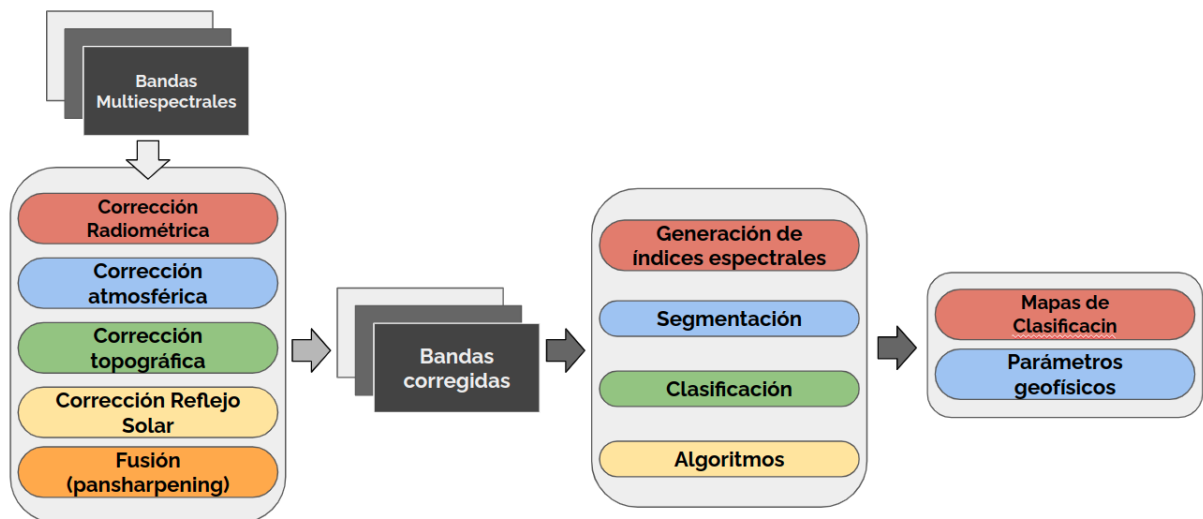


Figura 5.2: Diagrama de flujo de los distintos niveles de procesamiento aplicados a los datos satelitales. Adaptada de [101].

La estrategia seguida y la cadena de procesamiento implementada en este trabajo es por tanto la siguiente.

1. Descarga de los datos. Para este trabajo todas las imágenes descargadas eran de nivel 1C, por lo que las imágenes analizadas están corregidas radiométricamente y geométricamente, utilizando para ello puntos de control terrestre o información de posición integrada a bordo, pero no se han aplicado correcciones atmosféricas y se presenta en unidades de nivel digital (DN), que se pueden reescalar fácilmente a radiancia espectral o reflectancia en el techo de la atmósfera (TOA). Las imágenes fueron descargadas de los repositorios oficiales de la ESA y la NASA, [USGS Earth-Explorer²](https://earthexplorer.usgs.gov) y [Copernicus Open Access Hub³](https://scihub.copernicus.eu) respectivamente.

²<https://earthexplorer.usgs.gov>

³<https://scihub.copernicus.eu>

2. Preprocesamiento: En esta parte se emplea un modelo óptimo de corrección atmosférica y un algoritmo mejorado para la eliminación de reflejos solares basado en técnicas de procesamiento físico y de imágenes. Este paso se ha llevado a cabo gracias al software ACOLITE y la corrección atmosférica presentada en el apartado [4.2.2](#). También se emplean algoritmos de fusión de imagen o pansharpening para mejorar la resolución espacial, y se aplican filtros de paso medio o filtros gaussianos con los que se elimina el ruido de las imágenes, tal y como se ha comentado en el apartado [4.1](#).
3. Una vez obtenidas las bandas corregidas se emplean distintos algoritmos capaces de generar mapas o índices normalizados de las distintas variables asociadas a la calidad del agua. En este trabajo, como veremos en los apartados [5.1](#) y [5.2](#), los algoritmos van desde modelos de regresión lineal múltiple a redes neuronales simples.

A continuación se presenta el estudio realizado para las variables escogidas.

5.1. Estimación de la temperatura mediante teledetección

5.1.1. Datos in-situ

Si nos centramos primero en las medidas tomadas in-situ en el embalse de El Val, los perfiles métricos realizados por la sonda “Aquadam” entre los años 2018 y 2022 nos permiten estudiar la evolución y el carácter estacional de la temperatura superficial, a 1 m de profundidad, del agua durante este periodo (figura 5.3).

Aunque por razones de mantenimiento algunos periodos de tiempo la sonda no estuvo operativa, se han utilizado técnicas de interpolación de datos para estimar el valor de la temperatura en esos periodos y completar la serie temporal. El algoritmo de interpolación utilizado fue k-NN (K-Nearest Neighbor), el cual estima los valores perdidos con la media de los k vecinos seleccionados.

En la gráfica se muestran, por tanto, las medidas realizadas por la sonda en color negro, y los valores estimados mediante interpolación en color rojo.




Figura 5.3: Temperatura diaria medida en la superficie del embalse de “El Val” entre los años 2018-2022. Las medidas fueron tomadas por la sonda “Aquadam” situada en la zona más cercana a la presa. En negro se muestran las medidas tomadas por la sonda, mientras que en rojo los valores estimados mediante interpolación.

En la figura se puede distinguir claramente el carácter estacional de la temperatura, con mínimas que van desde aproximadamente $8^{\circ}C$ en los últimos días de enero, a máximas cercanas a los $25^{\circ}C$ en los últimos días de julio.

Es importante para el estudio conocer el rango usual en el cual oscila la temperatura superficial del agua, puesto que este será el rango en el que después se va a evaluar la temperatura estimada mediante teledetección. A continuación se muestran las temperaturas media, mínima y máxima para cada uno de los años analizados (tabla 5.3).

Año	2018	2019	2020	2021
Máximo	27.2	25.4	26.5	25.3
Mínima	7.2	8.1	8.2	7.4
Media	16.2	15.8	16.0	15.7

Tabla 5.3: Temperaturas máxima, mínima y media registradas en la superficie del embalse de “El Val” para los años 2018, 2019, 2020 y 2021.

Como se puede ver en la tabla, el rango de temperatura oscila entre los casi $7^{\circ}C$ registrados en 2018 y en 2021, y los $27^{\circ}C$ registrados en 2018, un rango de temperaturas relativamente amplio y útil para evaluar la precisión de los datos satelitales.

Por otro lado, la sonda proporciona la medida de la temperatura con una precisión de $0,1^{\circ}C$, pero a la hora de comparar estas medidas con las estimadas por teledetección es interesante estimar la variación observada diariamente. Podemos hacer una estimación de esta incertidumbre tomando los valores de la temperatura medidos por la sonda de forma consecutiva y calculando la variación relativa. La sonda “Aquadam” se encuentra operativa únicamente durante los perfiles, y no toma medidas en continuo el resto del tiempo, por lo que la forma de estimar esta incertidumbre fue calculando la desviación estándar de las medidas tomadas durante los perfiles de dos días consecutivos. Los datos de medición y los resultados se pueden encontrar a continuación en la tabla 5.4.

Fecha	Hora	Profundidad	Temperatura
dd/mm/YY	HH:MM:SS	(m)	(°C)
28/09/20	02:00:00	1.05	19.2
28/09/20	08:00:00	1.08	19.0
28/09/20	14:00:00	1.06	19.3
28/09/20	20:00:00	1.08	19.4
29/09/20	02:00:00	1.07	19.1
29/09/20	08:00:00	1.08	18.9
29/09/20	14:00:00	1.07	19.2
29/09/20	20:00:00	1.08	18.9
\bar{x}			19.1
σ			0.2

Tabla 5.4: Temperatura medida por la sonda “Aquadam” a 1m de profundidad los días 28 y 29 de septiembre de 2020, así como su valor medio y la desviación estándar.

Teniendo en cuenta estos valores, tomaremos $0,2^{\circ}C$ como incertidumbre en la temperatura estimada por la sonda a 1m de profundidad, a la hora de comparar las medidas estimadas mediante teledetección.

5.1.2. Metodología para la estimación de la temperatura superficial mediante teledetección

La temperatura superficial es una las variables fundamentales a la hora de monitorizar la calidad del agua ya que regula los procesos físicos, químicos y biológicos presentes en el agua. La estratificación térmica, la concentración de oxígeno disuelto, los procesos de fotosíntesis y la tasa de crecimiento de las algas o las floraciones masivas de estas, son solo algunos de los procesos sobre los que la temperatura tiene un gran impacto [102], por lo que disponer de una buena información sobre la distribución de la temperatura superficial del agua es crucial para comprender el funcionamiento hidrodinámico y los procesos fisicoquímicos y biológicos en lagos y embalses, y por tanto para la gestión de la calidad del agua.

En ausencia de observaciones de campo regulares, la teledetección satelital ha sido reconocida como una de las formas más rentables de monitorizar la temperatura superficial del agua a grandes escalas tanto espaciales como temporales. La banda térmica infrarroja, 8-14 μm , permite medir la cantidad de flujo radiante emitido por las superficies, y por lo tanto es útil para estimar la temperatura superficial del agua [103].

Aunque a menudo se han utilizado satélites con resolución espacial de kilómetros, como MODIS o AVHRR, para estimar la temperatura superficial de masas de agua, y aunque su uso resulta adecuado para la superficie oceánica, no lo es para masas de agua continentales debido al tamaño de estas, y a las interferencias que se producen en los píxeles situados en la frontera tierra-agua [104].

Los sensores infrarrojos térmicos (TIRS) a bordo de los satélites Landsat son, en cambio, ejemplos de herramientas adecuadas para monitorizar la temperatura superficial de lagos y embalses de tamaño pequeño a mediano. De hecho, se tiene constancia del uso de Landsat 5 y 7 para la estimación de la temperatura superficial del agua y la mejora del pronóstico de proliferaciones de algas nocivas [105].

El satélite Landsat 8 mide la temperatura de la superficie mediante las bandas 10 y 11 (tabla 5.5) del sensor TIRS, el cual está compuesto por foto-detectores infrarrojos de pozo cuántico (Quantum well Infrared Photodetector, QWIP) que miden la radiación infrarroja térmica de onda larga (Thermal Infrared Radiation, TIR) emitida por la superficie de la Tierra, cuya intensidad es función de la temperatura de la superficie.

Bandas	Longitud de onda	Resolución
Landsat 8	(μm)	(m)
*Banda 10 - TIRS 1	10.60 - 11.19	100
*Banda 11 - TIRS 2	11.50 - 12.51	100

Tabla 5.5: Distribución espectral de las bandas tomadas por el sensor TIRS de Landsat 8. *Las bandas TIRS se adquieren con una resolución de 100 metros, pero se remuestrean a 30 metros.

Los datos disponibles para descarga son imágenes con corrección de terreno de Nivel 1T con el sistema de coordenadas de proyección de UTM WGS84, y se entregan ortorrectificados utilizando puntos de control del terreno y datos del modelo de elevación digital (DEM), por lo que no fue necesaria ninguna corrección geométrica al procesar las imágenes de Landsat 8. Sin embargo, los datos TIR de Landsat 8 requieren de una calibración radiométrica para convertir el valor del número digital DN de la Banda 10 y la Banda 11 a la temperatura de brillo en lo alto de la atmósfera, o temperatura TOA (Top of the Atmosphere).

Para ello primero se convierte el valor DN a radiación espectral térmica mediante la fórmula 5.1, y luego la radiación espectral se puede convertir en temperatura de brillo mediante la función de radiación de Planck que se ve en la fórmula 5.2:

$$L_{sensor,\lambda} = a_{0,\lambda} + a_{1,\lambda} \cdot DN_{\lambda} \quad (5.1)$$

$$T_{\lambda} = \frac{K_2}{\ln\left(\frac{K_1}{L_{sensor,\lambda}} + 1\right)} \quad (5.2)$$

donde $L_{sensor,\lambda}$ ($W/(m^2 \cdot sr \cdot \mu m)$), corresponde a la radiancia espectral recibida por el sensor para cada banda, DN es el valor numérico digital, T (K) se corresponde con la temperatura de brillo TOA, y a_0 , a_1 , k_1 y k_2 son los coeficientes de calibración del sensor para cada banda. Estos coeficientes de calibración se proporcionan en el archivo de metadatos con cada imagen Landsat y toman los siguientes valores.

Banda	a_0	a_1	K_1 ($Wm^{-2}sr^{-1}\mu m$)	k_2 (k)	ϵ_{agua}
Banda 10	$3,342 \cdot 10^{-4}$	0.1	774.8853	1321.0789	0.9926
Banda 11	$3,342 \cdot 10^{-4}$	0.1	480.8883	1201.1442	0.9877

Tabla 5.6: Constantes para calcular la temperatura de brillo a partir de los datos del sensor infrarrojo térmico (TIR) Landsat 8.

No obstante, los datos satelitales están expuestos a los efectos atmosféricos y al ruido que estos introducen en las medidas. Es por ello que a lo largo del tiempo se hayan propuesto varios enfoques para corregir las contribuciones atmosféricas de estas medidas. A continuación se presenta el método utilizado en este trabajo.

5.1.3. Correcciones atmosféricas

En este trabajo las correcciones atmosféricas oportunas se realizaron mediante el software ACOLITE, el cual utiliza la herramienta TACT para la corrección de las bandas térmicas. TACT aplica el modelo de ecuación de transferencia radiativa para recuperar la radiancia emitida desde la superficie, $L_{\lambda(T_{RTE})}$, y la ecuación 5.2 para estimar la temperatura una vez calculada la radiancia.

– Ecuación de transferencia radiativa (RTE, Radiative Transfer Equation)

La radiancia medida por el sensor, o lo que es lo mismo, la radiancia en lo alto de la atmósfera o radiancia TOA, puede estimarse mediante la combinación de la radiancia emitida desde la superficie, $L_{\lambda(T_{RTE})}$, las radiancias atmosféricas ascendente y descendente, L_{up} y L_{down} , y la transmisividad de la atmósfera (τ), tal y como se puede ver en la siguiente fórmula:

$$L_{sensor} = \tau[\epsilon L_{\lambda}(T_{RTE}) + (1 - \epsilon)L_{down}] + L_{up} \quad (5.3)$$

donde ϵ es la emisividad del agua, y $L_{\lambda}(T_{RTE})$ la función de Planck para un cuerpo negro a temperatura T_{RTE} .

TACT utiliza el modelo meteorológico ERA5 para recuperar los perfiles atmosféricos, la biblioteca para transferencias radiativas libRadtran para calcular la transmitancia atmosférica y las radiaciones ascendentes y descendentes. Actualmente TACT proporciona la temperatura de la superficie del agua (WST) en cada banda térmica presente en el sensor Landsat, asumiendo una emisividad constante sobre la escena. El método y la validación del software con datos de Landsat 8/TIRS se pueden encontrar en [100].

5.1.4. Resultados en la estimación de la temperatura

Como hemos indicado, dos de las principales ventajas que aporta la teledetección a este campo recaen en su elevada capacidad para recoger datos a gran escala, haciendo posible monitorizar por completo toda la zona de interés mediante una sola imagen, realizando además la adquisición de los datos de forma continua y periódica, lo que permite seguir la evolución temporal y espacial de los parámetros a estudiar. Se presentan por tanto los resultados obtenidos desde dos perspectivas diferentes:

1. **Coherencia temporal:** se comparan los datos medidos por la sonda “Aquadam” frente a los resultados obtenidos mediante teledetección en ese mismo punto a lo largo de los cuatro años.
2. **Coherencia espacial:** se compara el ajuste de los mapas de temperatura obtenidos mediante teledetección con las medidas tomadas in-situ en diferentes puntos de muestreo seleccionados a lo largo del embalse.

– Coherencia temporal

Lo primero a comentar es que, una vez eliminadas las imágenes que o bien por nubes o bien por falta de calidad no son válidas para la estimación de la temperatura, el número final de imágenes disponibles es de 34, las cuales se distribuyen en 8 imágenes en 2018, 10 en 2019, 9 en 2020 y 7 en 2021.

Para esta parte del estudio se ha utilizado una superficie de aproximadamente 90x90 m, equivalente a 3x3 píxeles en la cabecera del embalse (ver figura 3.2). Las radiancias correspondientes a la superficie utilizada se calculan mediante la media de las radiancias correspondientes a cada uno de los píxeles.

Como se ha indicado, la temperatura de superficie se recupera mediante el software ACOLITE y su herramienta TACT la cual calcula la radiancia emitida desde la superficie mediante la ecuación de transferencia radiativa y la temperatura aplicando la ecuación 5.2.

El software, por tanto, una vez aplicado, nos devuelve las siguientes variables: Ls_{10} y Ls_{11} radiancias de superficie para las bandas B10 y B11 respectivamente, y ST_{10} y ST_{11} temperatura de superficie para estas mismas bandas.

Si representamos estas temperaturas de superficie recuperadas para las bandas térmicas B10 y B11 frente a la temperatura medida por la sonda “Aquadam”, tenemos (figura 5.4):




Figura 5.4: Temperatura medida in-situ en la superficie del embalse de “El Val” entre 2018-2022 (representada en línea continua negra), frente a la temperatura superficial estimada para las bandas B10 (en verde) y B11 (en azul) del satélite Landsat 8.

En la figura se puede ver que las temperaturas estimadas mediante las bandas térmicas se ajustan razonablemente bien a la temperatura medida por la sonda, siguiendo tanto el patrón estacional anual como la evolución a lo largo de los 4 años de medición. Sin embargo, y aunque la temperatura recuperada a partir de la banda 10 parece ajustarse mejor, las temperaturas máximas registradas por el satélite en ambos casos aparecen sobreestimadas, proporcionando unas temperaturas mayores que las medidas por el sensor.

Para estudiar mejor estos errores representamos los ajustes de la temperatura medida in-situ frente a las temperaturas estimadas y los histogramas de las diferencias entre temperaturas, separadas en diferentes tramos en función de la temperatura medida, figuras 5.5 y 5.6




Figura 5.5: Relación entre la temperatura medida in-situ en la superficie del embalse de “El Val” y las temperaturas estimadas mediante las bandas térmicas B10 (en verde) y B11 (en azul).

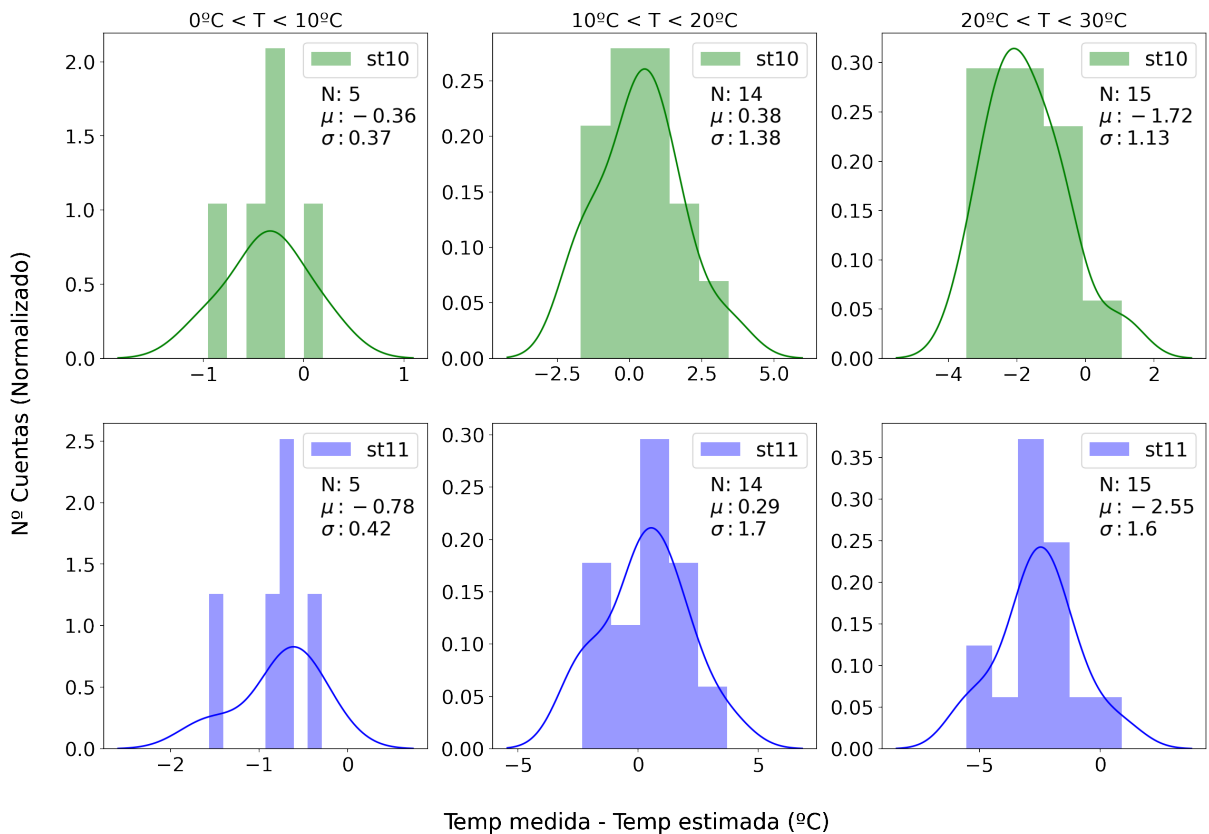


Figura 5.6: Histogramas que muestran la distribución del error cometido al estimar la temperatura mediante las bandas térmicas B10 (en verde) y B11 (en azul).

El coeficiente de correlación obtenido por los datos de temperatura satelital frente a las medidas tomadas in-situ es muy bueno, $R^2 = 0,96$ y $R^2 = 0,94$ para las bandas 10 y 11 respectivamente, pero el error medio cometido en ambos casos es superior a $1^\circ C$, e incluso superior a $3^\circ C$ para altas temperaturas como se puede ver en los histogramas. Corregir estos errores observados para altas temperaturas es muy importante para el planteamiento de este trabajo, la monitorización del estado trófico del embalse, ya que las mayores floraciones de algas se producen cuando el agua se encuentra a altas temperaturas.

Teniendo en cuenta los valores de correlación obtenidos para ambas bandas térmicas, es lógico intentar ajustar localmente modelos de regresión que nos permitan recuperar la temperatura de mediante los valores de radiancia de superficie para el embalse. Se presentan por tanto a continuación modelos de regresión lineales simples ajustados para cada una de las radiancias por separado, y un modelo de regresión lineal múltiple usando ambas bandas como variables predictoras, figura 5.7:

Cabe destacar que, para el ajuste y la validación de los modelos, se dividieron los datos locales disponibles en dos partes, empleando un 75 % (25 datos) para ajustar los modelos y calcular los coeficientes, y un 25 % (9 datos) para validar. De este modo, los datos de validación son independientes de los datos utilizados en el ajuste, y los modelos calculados pueden compararse mejor mediante los valores del coeficiente de correlación y las métricas RMSE (error cuadrático medio), MAE (Error absoluto medio) y MAPE (Error de porcentaje cuadrático medio).

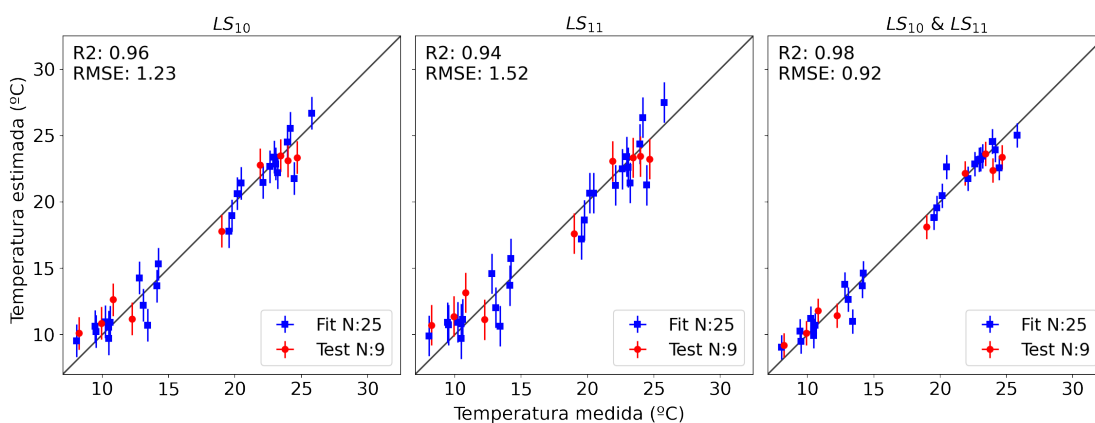


Figura 5.7: Modelos de regresión ajustados para estimar la temperatura superficial mediante las radiancias de las bandas térmicas B10 y B11. Se muestran en color azul los datos utilizados en el ajuste, y en color rojo los datos utilizados en los test.

5.1. ESTIMACIÓN DE LA TEMPERATURA MEDIANTE TELEDETECCIÓN

Modelo	Ajuste	R^2	RMSE (°C)	MAE (°C)	MAPE (%)
$Temp \sim ST_{10}$		0.96	1.14	0.95	5.0
$Temp \sim ST_{11}$		0.94	1.42	1.17	6.5
$Temp \sim Ls_{10}$	$T_{LS10} = 6,30 \cdot Ls_{10} - 35,73$	0.96	1.23	1.12	6.3
$Temp \sim Ls_{11}$	$T_{LS11} = 6,81 \cdot Ls_{11} - 36,88$	0.94	1.52	1.33	7.3
$Temp \sim Ls_{10}, Ls_{11}$	$T_{LS10,LS11} = 17,52 \cdot Ls_{10} - 12,25 \cdot Ls_{11} - 32,34$	0.98	0.92	0.79	5.2

Tabla 5.7: Coeficiente de correlación y métricas de los errores cometidos al estimar la temperatura superficial mediante los diferentes modelos propuestos.

El modelo que obtiene los mejores resultados es el modelo de regresión múltiple que utiliza ambas radiancias superficiales como variables predictoras, con un coeficiente de correlación, $R^2 = 0,98$. También es significativa la mejora en la estimación de la temperatura de este modelo con respecto a la temperatura calculada directamente por el software ACOLITE mediante la ecuación 5.2.

Presentamos por tanto a continuación, figura 5.8, los histogramas con las diferencias entre la temperatura medida in-situ y la estimada mediante la regresión múltiple.




Figura 5.8: Histogramas que reflejan el error cometido al estimar la temperatura mediante el modelo de regresión múltiple que utiliza ambas bandas térmicas, separado para distintos rangos de temperatura.

El modelo obtiene un error medio inferior a 1°C , lo que hace que mejore en ambos aspectos a la temperatura estimada a partir de una sola banda. Además, y según podemos ver en los histogramas, el modelo también se comporta mejor para los valores altos de la temperatura, donde el error cometido es menor de 2°C y sin bias.

Presentamos, por tanto, la evolución temporal de la temperatura estimada frente a la temperatura real medida por la sonda en el embalse, figura 5.9.




Figura 5.9: Evolución temporal de la temperatura medida por la sonda “Aquadam” en la superficie del embalse de “El Val” entre los años 2018-2022 frente a la temperatura estimada por regresión lineal múltiple empleando ambas bandas térmicas B10 y B11. Se muestran en color azul los datos utilizados en el ajuste, y en color rojo los datos utilizados en los test.

En el gráfico se puede apreciar que se han corregido los errores de sobreestimación reflejados para valores altos de temperatura. Como hemos comentado anteriormente, corregir la desviación que se producía a altas temperaturas es importante para este trabajo, ya que estas temperaturas son las más interesantes a la hora de monitorizar episodios de eutrofización.

Una vez obtenido el mejor ajuste, se plantea la posibilidad de estimar o medir la temperatura en el embalse únicamente mediante teledetección, sin emplear las medidas in-situ para el ajuste fino de las estimaciones.

Consideramos, por tanto, que solo se dispone de una sonda de medición durante un tiempo limitado, tiempo en el que las medidas reales tomadas por la sonda se emplean para calibrar la estimación mediante teledetección, para a partir de ese tiempo continuar la monitorización únicamente mediante teledetección, sin necesidad de disponer de medidas in-situ adicionales.

Para ello se procedió a ajustar el modelo únicamente con los datos disponibles en el primer año de medición, 8 imágenes disponibles para 2018, y medir después la temperatura el resto del tiempo contemplado en el estudio, años 2019, 2020 y 2021.

Se representa, por tanto, a continuación el ajuste lineal de los datos de temperatura medidos in-situ frente a los datos de temperatura estimados con el modelo de regresión múltiple ajustado únicamente con los 8 datos válidos encontrados en 2018, y testeado para el resto de imágenes válidas (26 datos de test) encontradas en el resto de años del estudio, figuras 5.10 y 5.11.




Figura 5.10: Comparación entre la temperatura medida in-situ y la temperatura estimada mediante el modelo de regresión lineal cuando este ha sido calibrado con los datos disponibles de 2018 (en azul), y testeado con los datos de 2019, 2020, 2021 (en rojo).




Figura 5.11: Histogramas que muestran la diferencia entre la temperatura medida in-situ y la estimada por regresión lineal, cuando el modelo ha sido calibrado con los datos de 2018.

Los resultados obtenidos para este ajuste son comparables a los obtenidos en el caso anterior en el que se ajustaba con el 75 % de los datos disponibles, lo que equivaldría a los datos de 3 años enteros, obteniendo un coeficiente de correlación $R^2 = 0,97$ y un error medio de $1^\circ C$.

Si presentamos por tanto la estimación de la evolución temporal de la temperatura en los tres años en los que no se utilizaron medidas in-situ adicionales para el ajuste fino, tenemos (figura 5.12):




Figura 5.12: Evolución temporal de la temperatura medida in-situ y estimada mediante regresión lineal en la superficie del embalse de “El Val” entre los años 2018-2022, cuando el modelo ha sido calibrado con los datos de 2018. Se muestran en color azul los datos utilizados en el ajuste, y en color rojo los datos utilizados en los test.

La temperatura estimada por teledetección se comporta razonablemente bien con respecto a la medida in-situ durante los tres años completos en los que se ha estudiado, lo que viene a confirmar que, una vez ajustado, el modelo de regresión es capaz de estimar la temperatura de superficie sin necesidad de recalibración periódica.

– Coherencia espacial

La segunda ventaja a analizar en la estimación de la temperatura mediante teledetección es su elevada capacidad para recoger datos a gran escala, haciendo posible monitorizar por completo toda la zona de interés mediante una sola imagen.

Esta característica se ha analizado mediante mediciones en varios puntos del embalse en un mismo día o momento. Se realizaron por ello 2 campañas de medición en el año 2020 en las cuales se tomaron medidas en todos los puntos presentados en el apartado 3.1 y en la tabla 3.3 mediante una sonda multiparamétrica modelo “Hydrolab”, de características similares a la sonda “Aquadam”. Estos días en los que se tomaron medidas en varios puntos del embalse fueron el 15/07/2020 y el 22/09/2020.

Se presentan a continuación los mapas de temperatura superficial de todo el embalse para los días más próximos a los días de campaña de medición.

– Primera campaña de medidas in-situ

El primer día de campaña fue el 15/07/2020, y la imagen disponible del satélite Landsat 8 más cercana a esa fecha la encontramos con una diferencia de dos días, el 13 de julio de 2020.




Figura 5.13: Mapa de la temperatura superficial estimada mediante teledetección en el embalse de “El Val” el 13/07/2020.

Puntos Muestreo	T medida “Hydrolab” (°C)	T estimada Landsat 8 (°C)	ΔT
E1	23.7	23.8	0.1
E2	23.5	23.6	0.1
E3	24.0	24.2	0.2
E4	23.5	23.6	0.1
E5	23.4	23.8	0.4
E6	23.5	24.0	0.5
E7	23.1	23.6	0.5
E8	23.0	23.5	0.5
E9	23.1	23.8	0.7
\bar{x}			0.3

Tabla 5.8: Temperatura medida in-situ (15/07/2020) y estimada (13/07/2020) mediante teledetección en los diferentes puntos de muestreo distribuidos a lo largo del embalse.




Figura 5.14: Comparación entre la temperatura medida in-situ (el 22/09/2020) y la temperatura estimada mediante teledetección (el 15/09/2020) para los diferentes puntos de muestreo distribuidos a lo largo del embalse de “El Val”.

Los resultados obtenidos para este día de medición son correctos, con un error medio menor de $1^{\circ}C$, y una correlación razonable dada la baja variabilidad de la temperatura a lo largo del embalse, con una diferencia máxima registrada de $1^{\circ}C$, (de 23 a $24^{\circ}C$).

Es importante mencionar que el desfase en el tiempo entre las medidas in-situ y las medidas del satélite Landsat 8 en este caso fue de dos días. Esta diferencia por lo general no es importante, ya que no presenta un gran cambio en la temperatura (menor de $0,5^{\circ}C$).

Podemos concluir por tanto, que el modelo de regresión múltiple es capaz de estimar la temperatura de forma correcta para otros puntos o zonas del embalse sin la necesidad de ajustar el modelo con datos de mediciones en estos puntos, ya que para esta parte de la validación se ha utilizado el mismo modelo que en la parte temporal, por lo que ninguno de los puntos aquí utilizados ha sido utilizado previamente para ajustar dicho modelo.

– Segunda campaña de medidas in-situ

El segundo día de campaña fue el 22/09/2020, sin embargo la imagen disponible más cercana a esa fecha la encontramos una semana antes, el 15 de septiembre de 2020. Si bien en el mapa antes presentado, con una diferencia de dos días entre ambas medidas, el intervalo no parece significativo como para tener que añadir un factor de corrección de la temperatura asociado a esta asincronía entre medidas, en este caso en el que la diferencia es una semana completa la temperatura del agua si ha podido variar lo suficiente como para distorsionar las medidas. Este factor de corrección lo podemos estimar mediante las temperaturas medidas por la sonda “Aquadam” para estos días, tabla 5.9.

Fecha dd/mm/YY HH:MM:SS	Profundidad (m)	Temperatura (°C)
16/09/20 14:00:00	1.05	21.8
17/09/20 14:00:00	1.04	21.8
18/09/20 14:00:00	1.07	21.1
19/09/20 14:00:00	1.04	20.9
20/09/20 14:00:00	1.06	20.8
21/09/20 14:00:00	1.06	21.1
22/09/20 14:00:00	1.05	20.7

Tabla 5.9: Temperatura medida por la sonda “Aquadam” entre los días 16-22 de septiembre de 2020.

Como se puede ver en la tabla, la temperatura en el intervalo de una semana si varía lo suficiente como para poder distorsionar las medidas tomadas, y podemos fijar un factor de corrección global en $1,1^{\circ}C$.

Se presenta el mapa de temperatura estimada para el día 15/09/2020 (figura 5.15).




Figura 5.15: Mapa de la temperatura superficial estimada mediante teledetección en el embalse de “El Val” el 15/09/2020.

En este caso se validaron todos los puntos disponibles después de quitar la cobertura nubosa, tabla 5.10

Puntos Muestreo	T medida “Hydrolab” (°C)	T estimada Landsat 8 (°C)	T estimada - 1.1 (°C)	ΔT
E4	21.0	21.2	20.1	0.9
E5	21.2	21.8	20.7	0.5
E6	21.1	22.1	21.0	0.1
E7	21.5	22.3	21.2	0.3
E8	21.1	22.2	21.1	0
E9	21.1	22.4	21.3	0.2
E10	21.3	23.1	22.0	0.7
\bar{x}				0.4

Tabla 5.10: Diferencia entre la temperatura medida y la estimada mediante teledetección en varios puntos del embalse el día 22/09/2020.




Figura 5.16: Comparación entre la temperatura medida in-situ (el 22/09/2020) y la temperatura estimada mediante teledetección (el 15/09/2020) para los diferentes puntos de muestreo distribuidos a lo largo del embalse de “El Val”.

Los resultados obtenidos para este día, a partir de una imagen tomada una semana antes del día en que se realizaron las medidas y de baja calidad debido a la cobertura nubosa existente, pueden calificarse de correctos, con un error medio menor de $0,5^{\circ}C$. Más si tenemos en cuenta la baja variabilidad de la temperatura registrada a lo largo del embalse, con una diferencia máxima de $0,5^{\circ}C$ (de $21^{\circ}C$ a $21,5^{\circ}C$).

5.1.5. Conclusiones sobre la estimación de la temperatura

Se ha estimado la temperatura superficial del agua en el embalse de “El Val” mediante teledetección para los años 2018, 2019, 2020 y 2021, y se han validado tanto temporal como espacialmente. Se han utilizado para ello las bandas térmicas del sensor TIRS del satélite Landsat 8.

Se ha observado que al calcular la temperatura de superficie del agua mediante el software ACOLITE, el cual estima la radiancia de superficie mediante el modelo de transferencia radiativa, y utiliza la ecuación 5.2 para calcular la temperatura correspondiente a cada radiancia, esta se sobreestima para altas temperaturas y se desvía valores por encima de $3^{\circ}C$.

Las altas temperaturas son las más interesantes en la monitorización de episodios de eutrofización debido a que es en esas circunstancias cuando se dan las floraciones de algas. Se ha corregido, por tanto, esta desviación a altas temperaturas ajustando un modelo de regresión múltiple utilizando ambas radiancias como variables predictoras.

Los resultados obtenidos por este modelo en el apartado de coherencia temporal muestran como este mejora la temperatura obtenida anteriormente, manteniendo un error medio menor de $1^{\circ}C$, y como además ajustando el modelo con muy pocos puntos, 8 puntos válidos en 2018, es capaz de extender las mediciones los tres años posteriores con buena confianza, $R^2 = 0,97$ y $RMSE = 1^{\circ}C$.

En el apartado de coherencia espacial se muestra además, que este modelo permite recuperar la temperatura de toda la superficie del embalse, produciendo mapas de temperatura fiables para cualquier punto de la masa de agua. En los mapas de temperatura presentados se muestra como incluso con condiciones climáticas desfavorables el modelo es capaz de recuperar la temperatura con un error medio menor a $0,5^{\circ}C$.

Una vez presentados y validados estos resultados concluimos que, la teledetección es una opción fiable con la que monitorizar por completo la temperatura de superficie de la masa de agua, tanto temporal como espacialmente.

5.2. Estimación de la turbidez y la concentración de clorofila-a

Además de las concentraciones de fósforo y nitrógeno, la concentración de clorofila-a y la transparencia del disco de Secchi (variable con una relación directa con la turbidez), son los dos parámetros claves para evaluar el estado ecológico de una masa de agua y clasificar su calidad en función de los niveles tróficos establecidos por la OCDE. La importancia de estos parámetros justifica un esfuerzo para monitorizar su evolución tanto en el tiempo, como en el espacio (distribución bidimensional a lo largo de la superficie del agua), dos de las áreas en las que más puede aportar la teledetección satelital.

Estos parámetros también se encuentran monitorizados en la cabecera de la presa por la sonda “Aquadam” en los diferentes perfiles métricos realizados cada 6 horas, lo que ha permitido estudiar su evolución durante el periodo 2018-2022.

5.2.1. Turbidez

– Datos in-situ

Representamos la turbidez media en la capa fótica del embalse (recordemos que la capa fótica en este caso se puede estimar que comprende a los 6 primeros metros de profundidad), tomada directamente de los datos en abierto de la Confederación Hidrográfica del Ebro, para los años 2018-2022 (figura 5.17). La unidad nefelométrica de la turbidez se expresa habitualmente con el acrónimo NTU (Nephelometric Turbidity Unit).




Figura 5.17: Evolución temporal de la turbidez media en la capa fótica del embalse de “El Val” en los años 2018-2022.

Lo primero que podemos ver en la gráfica es que la sonda refleja valores de saturación en la medida de la turbidez tomando valores anómalos en varias ocasiones. Estos datos no son válidos para el estudio, por lo que se procedió al curado de los datos para eliminar los valores atípicos presentes. El curado se realizó siguiendo los pasos indicados por la PYME Ecohydros, encargada del proyecto ya referido. Estos pasos se detallan a continuación.

1. Eliminar todos los perfiles con profundidad < 25 m. La sonda “Aquadam” se encuentra instalada en la zona de presa, donde la profundidad media a lo largo del año es de 35 m aproximadamente, por lo que los perfiles con una profundidad menor de 25 m se pueden clasificar como incompletos y en general erróneos.
2. Inspección visual de los perfiles buscando datos erróneos en los que por ejemplo se produzcan discontinuidades en los valores de alguna variable.
3. Filtro que elimina todos los perfiles con una turbidez registrada superior a 50 NTU, por considerar que todas estas medidas corresponden a valores de saturación.

Si representamos la evolución de la turbidez una vez curados los datos tenemos la siguiente gráfica (5.18), con el consiguiente cambio en la escala vertical.




Figura 5.18: Evolución temporal de la turbidez media en la capa fótica del embalse de “El Val” en los años 2018-2022 una vez eliminados los valores atípicos.

Con el proceso de curado se han eliminado todos los valores anómalos registrados, los cuales suponían una gran parte de las medidas disponibles (cerca del 25%). Se destaca en este aspecto el año 2020, en el que la sonda tomó valores considerados no anómalos solamente el 55% del tiempo.

Estimamos ahora, una vez curados los datos, la incertidumbre de estas medidas de turbidez.

Esta estimación se puede realizar tomando varias medidas consecutivas, y calculando la variación que se observa en en las mismas. Se presentan a continuación, tabla (5.11), los datos tomados por la sonda a 1, 2 y 3 m de profundidad en dos días consecutivos, 07/10/2020 y 08/10/2020.

5.2. ESTIMACIÓN DE LA TURBIDEZ Y LA CONCENTRACIÓN DE CLOROFILA-A

Fecha dd/mm/YY HH:MM:SS	Turbidez (NTU)						\bar{x}
	1m	2m	3m	4m	5m	6m	
07/10/20 02:00:00	28.2	28.3	29.2	27.7	27.0	27.4	28.0
07/10/20 08:00:00	28.7	30.7	28.6	29.0	27.8	27.6	28.7
07/10/20 15:00:00	1.1	2.4	6.5	6.0	1.8	0.4	3.0
07/10/20 20:00:00	11.8	17.3	27.0	8.6	0.1	0.2	10.8
08/10/20 02:00:00	13.1	7.7	2.2	0.3	0.3	0.5	4.0
08/10/20 08:00:00	7.2	2.5	0.5	0.6	0.1	0.2	1.8
08/10/20 14:00:00	13.4	5.9	1.3	0.3	0.4	0.0	3.6
08/10/20 20:00:00	0.5	0.5	0.6	0.6	0.1	0.2	0.3
\bar{x}							10.0
σ							11.0

Tabla 5.11: Turbidez medida por la sonda “Aquadam” en los perfiles de los días 7 y 8 de octubre de 2020, así como el valor medio y la desviación estándar calculados para las medidas presentadas.

La incertidumbre estimada muestra claramente un problema en la toma de datos de la turbidez, dado que esta es en algunos casos superior al 75 % de la medida registrada.

Si tenemos en cuenta el gran número de valores anómalos registrados, que reduce enormemente los datos válidos (se han eliminado más del 25 % de las medidas) con las que trabajar, y con un valor de incertidumbre superior en algunos caso al 75 % de la medida, que hace que los datos “válidos” tampoco tengan la calidad idónea para entrenar modelos de inferencia, no se ha considerado razonable entrenar modelos para estimar numéricamente la turbidez mediante teledetección

Por todos estos motivos no se ha considerado pertinente tratar de estimar la turbidez de la capa fótica del embalse de “El Val” mediante teledetección en este trabajo.

5.2.2. Clorofila

– Medidas in-situ

Lo primero a destacar en este apartado, es que tanto las medidas in-situ de las sondas, como las medidas estimadas mediante teledetección, no son realmente de la clorofila total de las algas sino que se trata de la clorofila-a, ya que como se vio en el capítulo 2, es uno de los parámetros más utilizados para determinar el nivel de eutrofización en el agua debido a que es el principal pigmento fotosintético presente en las algas.

La figura siguiente (5.19) representa, por tanto, la concentración de clorofila-a en la capa fótica del embalse entre los años 2018-2022. Recordemos que se ha estimado que la capa fótica comprende los seis primeros metros de profundidad, por lo que se representa es la concentración media de clorofila-a en ese rango.




Figura 5.19: Concentración media de clorofila-a medida en la capa fótica del embalse de “El Val” entre los años 2018-2022. Las medidas se fueron tomadas por la sonda “Aquadam” situada en la cabecera de la presa.

Si bien la figura 5.19 presenta algunos incrementos locales en la concentración de clorofila-a en distintas épocas del año, globalmente refleja un marcado carácter estacional, detectando los mayores picos de crecimiento o concentración en los últimos meses de verano y primeros de otoño. Este comportamiento se vuelve más evidente si representamos la concentración de clorofila-a registrada por meses, de forma que se agrupan las medidas tomadas para los 4 años, como muestra la figura 5.20 y resume la tabla 5.12

5.2. ESTIMACIÓN DE LA TURBIDEZ Y LA CONCENTRACIÓN DE CLOROFILA-A




Figura 5.20: Evolución anual de la concentración de clorofila-a detallada por meses.

El gráfico muestra la distribución anual completa de la concentración de clorofila-a, mostrando la densidad de probabilidad de los datos en las diferentes áreas representadas. En este caso el diagrama muestra que los picos de concentración de clorofila más importantes se producen en los meses de agosto, septiembre y octubre.

Mes	Valor medio de la concentración de clorofila-a ($\mu\text{g/l}$)	Dispersión de la concentración de clorofila-a ($\mu\text{g/l}$)
Enero	7.0	7.4
Febrero	11.1	9.7
Marzo	10.6	8.8
Abril	7.8	9.7
Mayo	12.6	9.7
Junio	16.3	8.6
Julio	35.1	19.1
Agosto	48.8	37.3
Septiembre	60.5	50.3
Octubre	40.7	37.1
Noviembre	4.3	4.2
Diciembre	2.6	1.1

Tabla 5.12: Evolución anual de la concentración de clorofila-a en la capa fótica del embalse de “El Val”, detallada por meses.

Como ya se había adelantado, la tabla 5.12 muestra claramente como en los últimos meses de verano y primeros de otoño, agosto, septiembre y octubre, es cuando se registran las mayores concentraciones de clorofila-a y por lo tanto las mayores floraciones de algas. Este crecimiento viene influenciado por varios factores como pueden ser la mayor temperatura del agua o la cantidad de radiación solar recibida, debido a un mayor tiempo de exposición a la luz.

También existe una gran influencia del año hidrológico, o lo que es lo mismo, el periodo de 12 meses a lo largo del cual se miden las precipitaciones sobre una determinada cuenca hidrográfica. El año hidrológico no coincide necesariamente con el año natural, para tener en cuenta que parte de la precipitación de otoño e invierno puede acumularse en forma de nieve y no fundirse hasta la siguiente primavera. La importancia del año hidrológico se debe a la influencia del ciclo del agua en las concentraciones de nutrientes (fósforo y nitrógeno principalmente) presentes en el agua.

Uno de los ejemplos más claros de esta influencia se da en los meses de verano, en los que usualmente la lluvia es menor y la sequía provoca que parte del suelo de los lagos y de los embalses quede al descubierto, liberando al agua gran parte de los nutrientes presentes en los sedimentos. El aporte extra de nutrientes, junto con las elevadas temperaturas y la mayor aportación de radiación en estos meses, crean las condiciones ideales para el crecimiento de algas.

Una vez estudiada la evolución anual, interesa estudiar el rango en el que usualmente oscila la concentración de clorofila-a, rango que podemos resumir en la tabla 5.13.

Concentración Chl-a ($\mu\text{g/l}$)				
Año	2018	2019	2020	2021
Máximo	244.6	115.0	102.3	187.7
Mínima	2.7	3.1	2.7	2.9
Media	28.6	22.0	16.1	20.9

Tabla 5.13: Concentración de clorofila-a máxima, mínima y media registradas en el embalse de El Val entre los años 2018-2022.

5.2. ESTIMACIÓN DE LA TURBIDEZ Y LA CONCENTRACIÓN DE CLOROFILA-A

Estos datos reflejan un rango amplio, que abarca valores que corresponden a todos los niveles tróficos establecidos por la OCDE, y suponen un conjunto de datos adecuado para evaluar la precisión de los datos satelitales.

De nuevo es importante conocer la incertidumbre en la medida de la clorofila-a. Una estimación podemos obtenerla tomando varias medidas registradas de forma consecutiva, y calculando la variación que se produce entre ellas. Se presentan a continuación, tabla 5.14, los datos tomados por la sonda entre 1-6 m de profundidad en dos días consecutivos, 26/07/2020 y 27/07/2020.

Fecha dd/mm/YY HH:MM:SS	Concentración Chl-a ($\mu\text{g/l}$)						
	1m	2m	3m	4m	5m	6m	\bar{x}
26/07/20 02:00:00	86.8	86.2	101.3	81.5	48.5	30.9	72.5
26/07/20 08:00:00	79.3	77.8	78.9	67.7	27.2	20.1	58.5
26/07/20 14:00:00	55.4	55.5	52.0	35.8	28.5	19.2	41.0
26/07/20 20:00:00	79.0	74.5	67.3	43.0	42.6	36.0	57.1
27/07/20 02:00:00	93.3	91.8	88.2	73.9	33.1	21.2	66.9
27/07/20 08:00:00	88.2	86.9	94.1	63.6	29.6	19.4	63.6
27/07/20 14:00:00	84.6	82.6	77.5	41.5	27.0	23.2	56.1
27/07/20 20:00:00	86.6	81.3	79.8	75.0	61.7	32.3	69.5
\bar{x}							60.6
σ							9.3

Tabla 5.14: Concentración de clorofila-a medida por la sonda “Aquadam” en los perfiles de los días 26 y 27 de julio de 2020, así como el valor medio y la desviación estándar calculados para las medidas presentadas.

Es importante recordar que el propósito de este trabajo es estimar la concentración de clorofila-a en la capa fótica del embalse, la cual se ha estimado se corresponde a los 6 primeros metros de profundidad. Esto significa que en este apartado no buscamos la incertidumbre de la concentración de clorofila-a en cada metro, si no en el conjunto de la capa fótica, y es por ello que se tomen los 6 primeros metros para calcular la incertidumbre.

La tabla 5.14 muestra que la incertidumbre asociada a está estimación de la concentración de clorofila, está en el rango del 10%.

– **Algoritmo de Estimación de la Concentración de Clorofila-a**

En la teledetección orientada a la valoración de la calidad del agua, la clorofila-a es solo uno de los varios componentes ópticamente activos que contribuyen al espectro R_{rs} (reflectancia de la superficie). Por ejemplo, la absorción de clorofila-a en la región azul se superpone con la que corresponde a la materia orgánica disuelta (CDOM).

Como resultado, varias combinaciones de concentraciones constituyentes diferentes pueden corresponder a un mismo espectro R_{rs} , o lo que es lo mismo, diferentes concentraciones de clorofila-a pueden corresponder a un mismo espectro R_{rs} dando lugar al problema de la no unicidad de la solución [106, 107].

En este trabajo se estudia la posibilidad de estimar la concentración de clorofila-a, mediante un algoritmo que evalúa el espectro R_{rs} completo, utilizando todas las bandas MSI disponibles del satélite Sentinel-2, en vez de utilizar solo parte de ellas mediante índice de calidad, proporcionando una buena solución al problema indicado, una vez calibrado el modelo en la masa de agua a estudiar.

Red neuronal artificial, ANN

– Input y Output

La entrada al modelo consiste en el espectro completo R_{rs} , medido por el sensor MSI del satélite Sentinel-2 dentro del rango de 400 a 800 nm, lo que incluye nueve bandas espectrales (Bandas 1-8A). La salida del modelo consiste en la estimación de la concentración de la clorofila-a.

El modelo se entrena utilizando emparejamientos de mediciones in-situ realizadas bajo los pasos de los satélites Sentinel-2A/B, que se obtienen a través de actividades de monitorización o a través de visitas de campo.

Además, todos los parámetros tanto de entrada como de salida se normalizan centrando la mediana y la escala intercuartil, y luego se escalan al rango (0,1). Este procedimiento, usual en ANN, es más resistente a los valores atípicos que pueden estar presentes en los datos, al mismo tiempo que impone una escala y distribución homogéneas entre las características.

Hiperparámetros

Los hiperparámetros de ajuste de la red neuronal son los básicos para estos tipos de algoritmos: tasas de regularización y de aprendizaje, tamaño y profundidad de la red, etc. Aunque estos parámetros resultaron ser bastante robustos a los cambios dentro de una implementación normal de una red, se realizó una validación cruzada en la cual se dividieron los datos de entrenamiento disponibles (dejando de lado los datos de test) entre datos de entrenamiento y datos de validación (80 % entrenamiento, 20 % validación), y se experimentó con varias arquitecturas diferentes con el fin de optimizar parámetros tales como el tamaño o la profundidad de la red, teniendo también en cuenta el tiempo empleado por la red para el entrenamiento.

Debe tenerse en cuenta que se dispone de un número reducido de datos para entrenar la red, aproximadamente 85 imágenes, en el punto de muestreo.




Figura 5.21: Evolución de la función de pérdida obtenida en función de la arquitectura de la red. En azul se muestra el valor de la función de pérdida para los datos de entrenamiento, mientras que en rojo se muestran los obtenidos durante la validación.

Debido a la limitación en el número de datos, y teniendo en cuenta los valores obtenidos para la función de pérdida en las diferentes arquitecturas probadas, se eligió usar una red neuronal con dos capas de profundidad y 10 neuronas por capa.

Esta arquitectura hace que la red sea muy rápida y ágil a la hora de entrenar, lo que facilita mucho el trabajo a la hora de cambiar el dataset de entrenamiento para por ejemplo, aumentar este dataset cuando se dispongan de más medidas a evaluar.

La función de pérdida escogida para entrenar la red ha sido el error cuadrático medio entre cada estimación y el objetivo, y se estableció un tasa de aprendizaje que decrece en las últimas etapas de entrenamiento para facilitar que la función de pérdida converja.

Corrección atmosférica

ACOLITE, cuyo rendimiento para las imágenes multispectrales se ha mostrado prometedor incluso en aguas muy turbias [98, 99], es el software que se ha utilizado para corregir las bandas MSI. La versión actual de ACOLITE (20210114.0) aplica un esquema de ajuste de espectro oscuro (DSF) como configuración predeterminada [100], el cual cuenta ahora además con la opción de corrección del destello solar.

Esto hace que los espectros R_{rs} recuperados sean lo más reales posibles y estas correcciones nos permitan después estimar las concentraciones de clorofila-a. A continuación, en la figura 5.22, se presenta un ejemplo de los espectros de reflectancia en la parte superior de la atmósfera, ρ_{TOA} y la reflectancia de la superficie para píxeles de agua, ρ_w y R_{rs} , donde $R_{rs} = \rho_w/\pi$.




Figura 5.22: Espectros de reflectancia ρ_{TOA} (reflectancia en la parte superior de la atmósfera), ρ_w y R_{rs} (reflectancia de la superficie para píxeles de agua), tomados por el satélite Sentinel-2 en el embalse de “El Val” el 15/10/2021.

Los productos de reflectancia de la superficie terrestre generados a partir de las correcciones atmosféricas se utilizaron como entrada en los algoritmos para la recuperación de la concentración de clorofila.

Indicadores de rendimiento del método

Las métricas de rendimiento utilizadas son: RMSE, MAPE, MAE y Bias; donde RMSE es el error cuadrático medio, MAPE es el error porcentual absoluto medio, MAE es el error absoluto medio y Bias representa los residuos transformados logarítmicamente.

Los indicadores o valores estadísticos utilizados para medir el rendimiento proporcionan una mejor evaluación de los algoritmos, debido a que estos evalúan los datos no solo en el espacio natural, sino que también lo hacen en su distribución logarítmica. Ej, un bias de 1,5 implica que las estimaciones de Chla son, en promedio, un 50 % más grandes que las medidas.

Para cualquiera de las variables presentadas la evaluación de todos los algoritmos se realiza mediante un conjunto de datos de test, independiente del conjunto de datos utilizados en el entrenamiento.

– Resultados

La forma validar los resultados obtenidos para la clorofila-a es la misma que en el caso de la temperatura superficial, por lo que primero se presenta la validación de los resultados para la coherencia temporal y después la coherencia espacial.

– Coherencia temporal

Como se ha comentado en el apartado anterior [5.2.2](#), y después de probar con diferentes arquitecturas, el algoritmo escogido para estimar la concentración de clorofila-a en el embalse a partir de imágenes satelitales es una red neuronal con 2 capas de profundidad y 10 nodos por capa. Esta arquitectura permite que la red sea muy ágil y rápida tanto a la hora de entrenar como de predecir, lo que facilita enormemente el trabajo a la hora de incorporar o cambiar datos en el dataset de entrenamiento.

Recordar que se ha trabajado con los datos medidos por la sonda “Aquadam” instalada en la zona de la presa del embalse de “El Val” entre los años 2018-2021, ambos incluidos, lo que, después de un trabajo intenso de curación de los datos, tanto de los datos medidos in-situ, con eliminación de outliers, como de las imágenes satelitales, para eliminar todas aquellas con cobertura nubosa o de baja calidad, nos queda un total de 88 medidas las cuales se distribuyen en 16 imágenes en 2018, 23 en 2019, 22 en 2020 y 27 en 2021.

Para la primera parte de la modelización se dividieron los datos en dos partes de forma aleatoria, de modo que el 80 % de ellos (70 datos) se destinaron a datos de entrenamiento, mientras que el otro 20 % (18 datos) se utilizó para testear el modelo. De este modo, todas las métricas utilizadas para estimar la precisión del algoritmo, se calcularon utilizando únicamente estos datos de test, los cuales son independientes de los datos utilizados para los entrenamientos.

Se presenta a continuación, figura [5.23](#), el ajuste realizado con los valores de clorofila-a estimados mediante teledetección frente a los valores medidos in-situ, así como varios histogramas, figura [5.24](#), en los que se presentan los errores cometidos para diferentes tramos de la concentración de clorofila-a medida.

Los diferentes tramos de concentración de clorofila-a se han seleccionado en función de los niveles tróficos establecidos por la OCDE, y más concretamente, para los valores límites de concentración fijados para dichos niveles [2.1](#). Así pues los diferentes tramos propuestos quedan de la siguiente manera:

- Concentración de clorofila-a muy baja. Conc. Chl-a $< 8.0 \mu\text{g}/\text{l}$. Equivale a los niveles ultraoligotrófico y oligotrófico.
- Concentración baja. $8.0 < \text{Conc. Chl-a} < 25 \mu\text{g}/\text{l}$. Equivale a un nivel mesotrófico.
- Concentración media. $25 < \text{Conc. Chl-a} < 75 \mu\text{g}/\text{l}$. Equivale a un nivel eutrófico.
- Concentración alta. $75 \mu\text{g}/\text{l} < \text{Conc. Chl-a}$. Equivale a un nivel hipereutrófico.




Figura 5.23: Relación entre la concentración media de clorofila-a medida in-situ y estimada mediante teledetección, para la capa fótica del embalse de El Val entre los años 2018-2022. En azul se muestran los datos empleados en el entrenamiento de la red, mientras que en rojo los utilizados en los test.

Como se puede ver en las gráficas el modelo entrenado presenta buenos resultados en la comparación, con un coeficiente de correlación $R^2 = 0,82$, y un RMSE de $11\mu\text{gr}/l$. El modelo es capaz de clasificar bien los valores de concentración muy baja, baja y media.

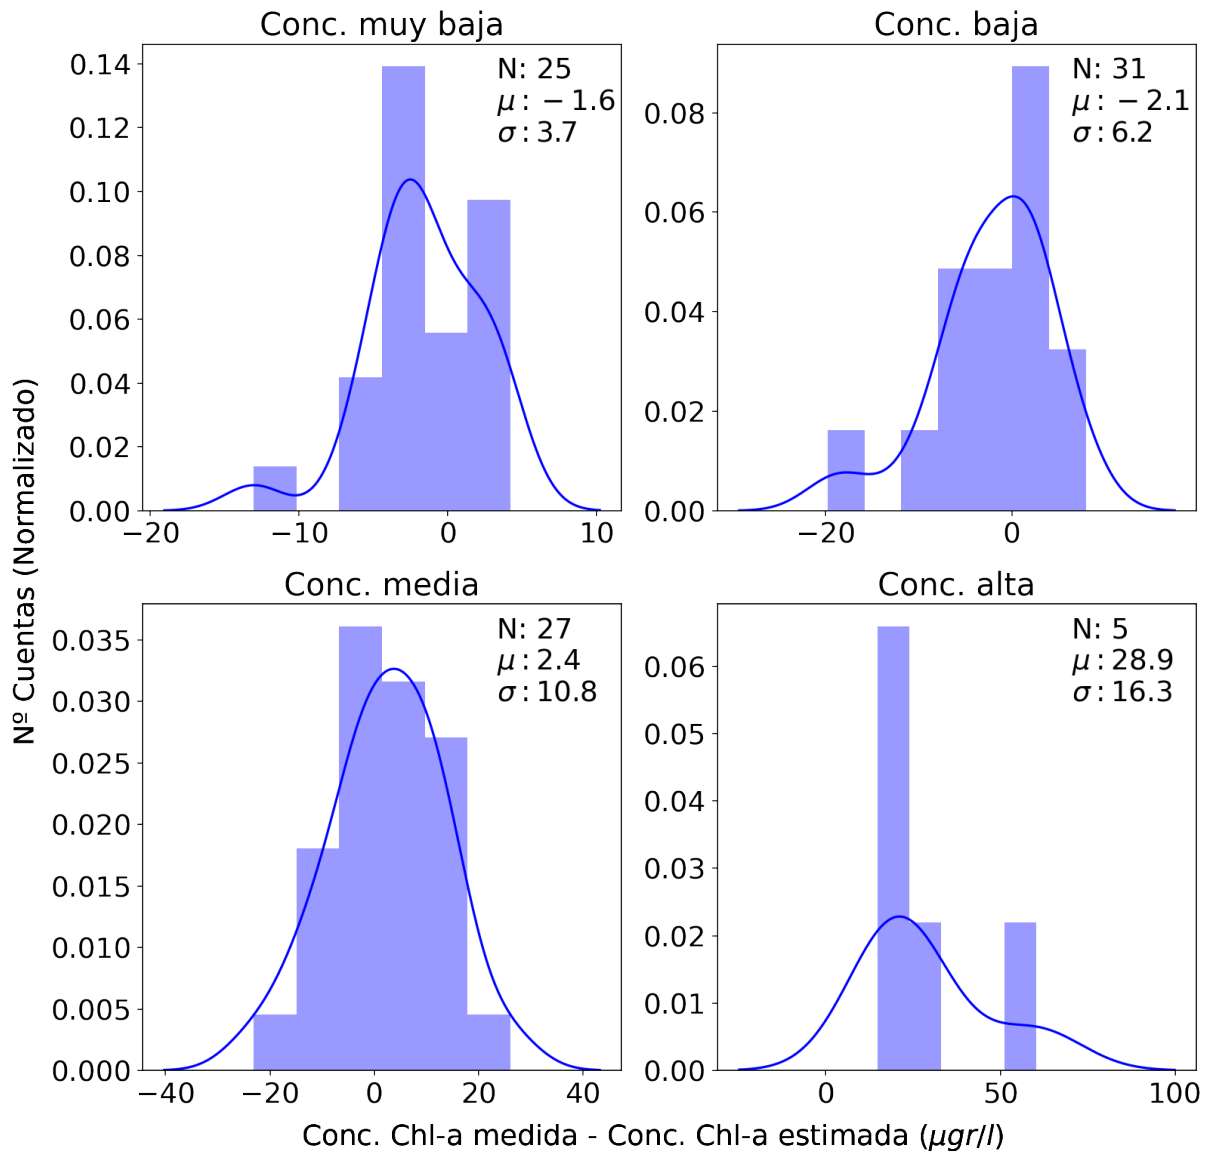


Figura 5.24: Histogramas que muestran la distribución del error cometido al estimar la concentración de clorofila-a mediante teledetección, separado por rangos de concentración.

Estos resultados se confirman en los histogramas divididos por rangos de concentración, donde podemos ver que el error es pequeño tanto para valores de concentración muy baja, como para valores bajos o medios, pero crece por encima de los $25 \mu\text{gr/l}$ para valores de concentración alta.

La razón principal para este desfase observado al estimar los valores de alta concentración, la podemos encontrar en la baja cantidad de datos disponibles en ese rango con los que entrenar el modelo, ya que como se puede ver también en los histogramas, en los demás niveles el número de datos evaluados es de al menos 25 datos, mientras que en el caso de concentraciones altas son solo 5 los valores encontrados. De hecho, el error cometido en ese rango se ve extremadamente influenciado por el único dato encontrado en el que la concentración de clorofila-a medida in-situ es mayor de $100 \mu\text{gr}/\text{l}$, dato para el cual la estimación es aproximadamente de $60 \mu\text{gr}/\text{l}$.

Esta diferencia encontrada en el número de datos disponibles para cada uno de los niveles fijados, hace que el dataset con el que se trabaja no este correctamente balanceado y el modelo no sea capaz de aprender por igual las características de cada uno de los rangos.

Para evaluar mejor el rendimiento y la precisión del algoritmo entrenado, los resultados obtenidos se comparan con las métricas presentadas por algunos de los algoritmos de última generación encontrados en bibliografía:

Algoritmo	R^2	RMSE ($\mu\text{g}/\text{l}$)	MAE ($\mu\text{g}/\text{l}$)	Referencia
ANN	0.80	11.4	8.2	Este trabajo
LGBM	0.75	15.1	9.5	[108]
RF	0.69	17.8	9.2	[108]
MLP	0.58	19.1	10.5	[108]
GPR	0.53	21.0	10.8	[108]
Blending	0.41	23.5	10.8	[108]
SVM	0.46	22.6	11.5	[108]

Tabla 5.15: Comparación de los resultados obtenidos en este estudio frente a otros encontrados en otro estudio de la bibliografía.

En la tabla [5.15](#) se puede ver que el algoritmo empleado en este trabajo también ha obtenido muy buenos resultados en comparación con el resto de modelos de machine learning utilizados en otro estudio encontrado en la bibliografía, obteniendo un mejor coeficiente de correlación, y un error medio inferior al de todos los otros modelos.

Una vez validado el modelo podemos presentar la evolución temporal de la clorofila-a estimada frente a la clorofila-a real, medida por la sonda en el embalse, figura [5.25](#).




Figura 5.25: Evolución temporal de la clorofila-a medida por la sonda “Aquadam” en la capa fótica del embalse de “El Val” entre los años 2018-2022 frente a la clorofila-a estimada mediante teledetección. En rojo azul se muestran los datos utilizados para entrenar el modelo, mientras que en rojo se muestran los utilizados en los test.

En esta figura podemos ver que los datos de clorofila-a estimados mediante teledetección se ajustan razonablemente bien a la serie temporal marcada por las medidas realizadas in-situ tanto en las zonas de concentración baja como en los picos de concentración alta.

Una vez validado el algoritmo empleado, el siguiente paso consiste en estudiar la evolución temporal de la concentración de clorofila-a estimada mediante teledetección frente a la clorofila-a medida por la sonda en el embalse.

En esta parte se quiere reflejar el comportamiento de la concentración estimada mediante teledetección en el supuesto de que solo se dispone de una sonda de medición durante un tiempo limitado, tiempo en el que las medidas reales se emplean para entrenar la red, para a partir de ese tiempo continuar la monitorización únicamente mediante teledetección, sin necesidad de disponer de medidas in-situ.

Se decidió para ello entrenar el modelo con los datos de los dos primeros años (2018 y 2019), y testear este con los dos años siguientes. Entrenar el modelo con las medidas tomadas durante el primer año supondría disponer únicamente de 16 datos con los que entrenar el modelo, lo que casi con seguridad nos llevaría a un modelo sobreajustado.

Se presenta por tanto a continuación, figura 5.26, el ajuste realizado para los valores de clorofila-a estimados para los años 2020 y 2021, así como la evolución temporal de estas medidas frente a los valores medidos in-situ, figura 5.27.

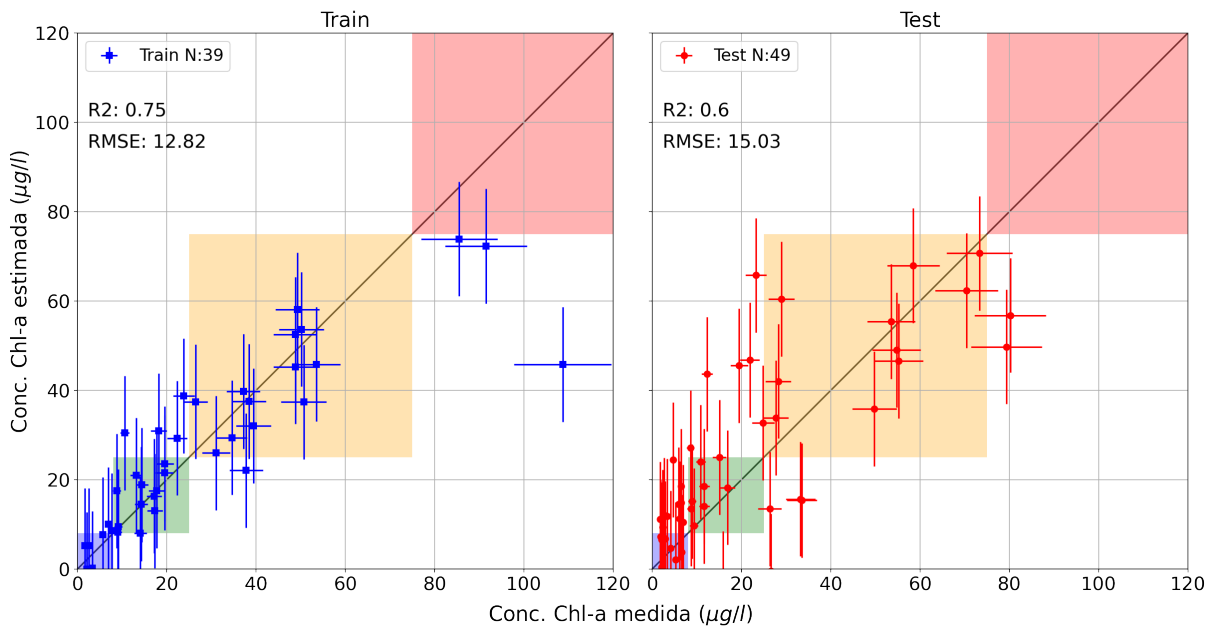


Figura 5.26: Relación entre la concentración de clorofila-a medida in-situ y estimada mediante teledetección, cuando la red neuronal ha sido entrenada con los datos de los dos primeros años (2018 y 2019, en azul) y validada con los dos años siguientes (2020 y 2021, en rojo).




Figura 5.27: Evolución temporal de la clorofila-a medida por la sonda “Aquadam” frente a la clorofila-a estimada mediante teledetección, cuando la red neuronal ha sido entrenada con los datos de los dos primeros años (2018 y 2019, en azul) y validada con los dos años siguientes (2020 y 2021, en rojo).

Como se puede ver en las figuras, si bien el error cometido al estimar la clorofila-a aumenta con respecto a el primer modelo presentado, entrenado con el 80% de los datos (70 datos) escogidos aleatoriamente, las estimaciones realizadas para este nuevo modelo, entrenado únicamente con dos años de medidas in-situ (39 datos), son capaces de seguir la evolución temporal de la clorofila-a en los dos años siguientes a su calibrado y obtener buenos resultados en las medidas.

– Coherencia espacial

Al igual que con la temperatura, en esta parte se pretende validar la elevada capacidad de la teledetección para recoger datos a gran escala, haciendo posible monitorizar por completo toda la zona de interés mediante una sola imagen.

Se realizaron dos campañas de medición en el año 2020 en los cuales se tomaron medidas en todos los puntos presentados en el apartado 3.1 y en la tabla 3.3 mediante una sonda multiparamétrica. Estos días en los que se tomaron medidas en varios puntos del embalse fueron el 15/07/2020 y el 22/09/2020, si bien en este caso solo se pudo validar con uno de ellos, el 15/07/2020, ya que en el caso del día 22/09/2020 la imagen disponible más cercana a esa fecha no se encuentra hasta pasados los 9 días.

– Primera campaña de medidas in-situ

El primer día de campaña se realizó el 15/07/2020, pero la imagen disponible más cercana a esa fecha la encontramos 2 días después, el 17 de Julio de 2020.

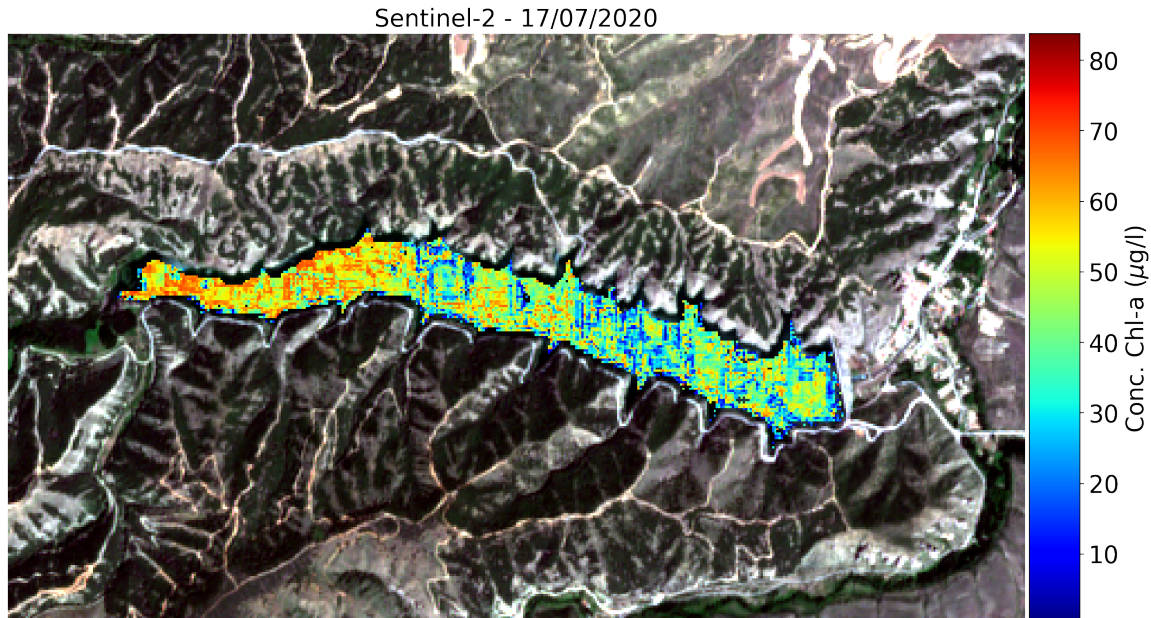


Figura 5.28: Mapa de la concentración de clorofila-a estimada mediante teledetección, en el embalse de “El Val” el día 17/07/2020.

5.2. ESTIMACIÓN DE LA TURBIDEZ Y LA CONCENTRACIÓN DE CLOROFILA-A

Puntos Muestreo	Conc. Ch-a medida "Hydrolab" ($\mu\text{g/l}$)	Conc. Chl-a estimada Sentinel-2 ($\pm 11,4 \mu\text{g/l}$)	$\Delta\text{Conc. Chl} - a$ ($\mu\text{g/l}$)
E1	37,2 \pm 3,7	36,1	1.1
E2	49,4 \pm 4,9	35,0	14.4
E3	25,1 \pm 2,5	35,2	10.1
E4	26,9 \pm 2,7	23,7	3.2
E5	31,3 \pm 3,1	26,1	5.2
E6	33,8 \pm 3,4	38,6	4.8
E7	38,3 \pm 3,8	31,4	7.4
E8	34,8 \pm 3,5	34,4	0.4
E9	26,4 \pm 2,6	41,8	15.4
E10	53,2 \pm 5,3	58,2	5.0
E11	58,2 \pm 5,8	59,5	1.3
E12	61,6 \pm 6,2	53,3	8.3
\bar{x}			4.2

Tabla 5.16: Concentración de clorofila-a medida in-situ (15/07/2020) y estimada mediante teledetección (17/07/2020) en puntos de muestreo distribuidos a lo largo del embalse.




Figura 5.29: Comparación de las medidas tomadas in-situ (el 15/07/2020) en los diferentes puntos de muestreo distribuidos por el embalse frente a la clorofila-a estimada mediante teledetección (el 17/07/2020) en esos mismos puntos.

Los resultados obtenidos para este día de medición se pueden considerar como muy buenos, con un error medio de $4 \mu g/l$, y con una gran parte de las medidas con discrepancias por debajo de $10 \mu g/l$. También cabe comentar que los puntos en los que se observa una mayor discrepancia, E2 y E9, se encuentran situados muy próximos a la orilla del embalse, lo que puede hacer que la estimación mediante teledetección en estos puntos se vea afectada por las interferencias con las zonas de tierra.

Mencionar también que el día en el que el satélite toma los datos es 2 días después del muestreo in-situ, lo que por lo general, y más teniendo en cuenta lo rápido que cambian las condiciones en las floraciones de algas, este desfase temporal puede alterar ligeramente la validación.

Recordar además que, en esta parte de la validación se ha utilizado el mismo modelo que en el apartado de validación temporal, por lo que ninguno de estos puntos ha sido utilizado para ajustar dicho modelo.

Una vez analizados los datos podemos concluir que el modelo es capaz de estimar la concentración de clorofila-a de forma fiable en diferentes zonas del embalse sin la necesidad de recalibrar el modelo con medidas in-situ de estos puntos.

– **Evolución de una floración de algas**

Puesto que para esta validación espacial solo se dispone de un día de mediciones in-situ, y aunque no se tienen medidas reales con las que validar los niveles de concentración de clorofila-a estimados en el embalse mediante teledetección, en esta sección parece interesante presentar la evolución tanto temporal como espacial de alguno de los picos de clorofila-a registrados, comparando varias imágenes sucesivas en el tiempo.

Se presenta por tanto a continuación el pico de clorofila-a registrado entre julio y agosto de 2020, en el cual la concentración llegó a niveles considerados como hipereutróficos, con valores por encima de los $80 \mu\text{g/l}$.




Figura 5.30: Evolución temporal de la concentración de clorofila-a medida in-situ y estimada mediante teledetección entre los meses de julio y agosto de 2020.

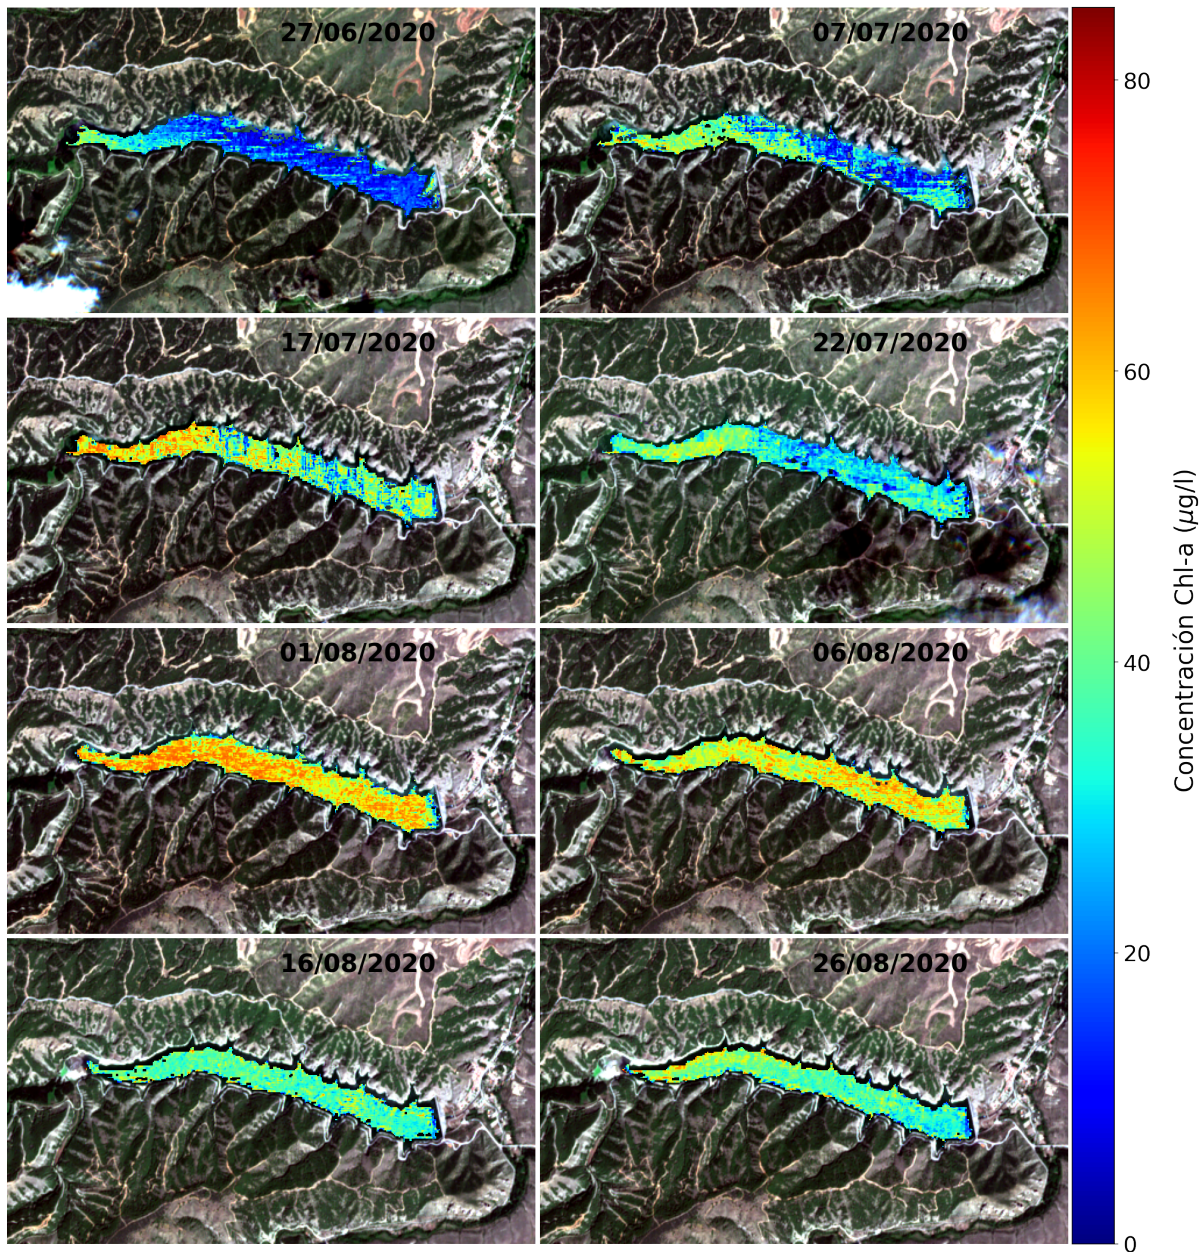


Figura 5.31: Evolución temporal y espacial de la concentración de clorofila-a estimada mediante teledetección del pico registrado entre julio y agosto de 2020. La evolución temporal se presenta mediante mapas consecutivos estimados mediante los datos del satélite Sentinel-2.

En las imágenes se puede ver un evento de floración de algas el cual se produce entre los meses de junio y agosto. Esta floración de algas comienza en la zona de la cola del embalse a primeros de julio, y se va extendiendo por todo el embalse hasta alcanzar el máximo de concentración en los primeros días de agosto, donde ya la floración de algas se puede encontrar por todo el embalse.

Este es un ejemplo perfecto de lo que la teledetección puede aportar a este campo, monitorizando el evento de eutrofización del embalse con imágenes cada 5 o 10 días, en las cuales se puede captar la zona más afectada y el comportamiento de este evento a lo largo del tiempo, permitiendo tomar medidas al respecto.

5.2.3. Conclusiones

Se ha entrenado una red neuronal para estimar la concentración de clorofila de un embalse y monitorizar los posibles episodios de eutrofización mediante las imágenes del satélite Sentinel-2. Este modelo evalúa todo el espectro R_{rs} comprendido entre 400 y 800 nm, utilizando todas las bandas MSI disponibles para estimar la cantidad de clorofila presente en el agua. Al evaluar todo el espectro comprendido entre 400 y 800 nm, este planteamiento tiene ventaja frente a los métodos tradicionales los cuales se centran en el desarrollo de índices espectrales y la comparación de la reflectancia observada en ciertas longitudes de onda concretas.

La red obtiene buenos resultados en el apartado que valida la coherencia temporal, con un coeficiente de correlación $R^2 = 0,8$ y un error medio inferior a $11.5 \mu g/l$. El método también mejora los resultados obtenidos por otros algoritmos de machine learning encontrados en el estado del arte. La red además, es capaz de extender de forma fiable las medidas de la concentración siendo únicamente entrenada con unos pocos datos. En este caso una red entrenada con los datos disponibles de dos años de mediciones, fue capaz de extender las medidas durante al menos otros 2 años.

El modelo presenta también muy buenos resultados en el apartado de coherencia espacial, obteniendo una diferencia media inferior a los $5 \mu g/l$. Estos resultados demuestran que este modelo permite recuperar la concentración de clorofila de toda la superficie del embalse, produciendo mapas de clorofila fiables para cualquier punto de la masa de agua. Además, y gracias al tiempo de revisita del satélite Sentinel-2, 5 días, se ha podido monitorizar tanto el comportamiento temporal como el espacial de un evento de floración de algas.

Una vez presentados y validados estos resultados podemos afirmar que, la teledetección también puede ser una opción fiable con la que monitorizar la concentración de clorofila en las masas de agua continentales.

Capítulo 6

Conclusiones

El estudio de la calidad del agua mediante teledetección se basa en la identificación y cuantificación de sustancias disueltas o partículas en suspensión presentes en el agua que modifican sus propiedades ópticas. Dicha influencia provoca cambios en la absorción y en la reflexión de la radiación en el agua, que pueden detectarse mediante la firma espectral de la luz reflejada y emplearse para estimar los valores de parámetros indicadores de la calidad del agua.

Los dos parámetros clave a monitorizar en una masa de agua, utilizados para clasificar su calidad en función de los niveles tróficos establecidos por la OCDE, son su transparencia, mediante la medida de la profundidad del disco de Secchi como indicador de la turbidez del agua, y la concentración de clorofila. La temperatura superficial del agua, relacionada directamente con la regulación de los procesos físicos, químicos y biológicos presentes en el agua, también es considerada como una variable fundamental a monitorizar.

Las principales ventajas que aporta la teledetección a este campo son su elevada capacidad para recoger datos a gran escala, haciendo posible monitorizar por completo una extensa zona de interés mediante una sola imagen, realizando además dicha adquisición de los datos de forma continua y periódica, lo que permite seguir la evolución de los parámetros a estudiar durante años. Una sola imagen satelital equivale a semanas de medidas de campo.

6.1. Método y resultados en el embalse

El principal inconveniente lo encontramos en la cobertura nubosa, la cual puede llegar a ser muy frecuente en función de la región que se quiera monitorizar. En este caso podemos clasificar la cobertura nubosa en la zona de estudio como intensa, reduciendo en gran medida el número de datos disponible y dejando en tan solo 34 (de 89 totales, un 38 %) imágenes válidas para Landsat 8 y 88 (de 287 totales, un 30 %) imágenes para de Sentinel-2.

Se ha ajustado un modelo de regresión el cual utiliza las bandas térmicas del satélite Landsat-8 para corregir una sobreestimación observada en los valores altos de temperatura recuperados mediante el software ACOLITE, el cual utiliza el modelo de transferencia radiativa para aplicar las correcciones atmosféricas. Los resultados obtenidos por este modelo mejoran notablemente la temperatura obtenida, manteniendo un error medio menor de 1°C .

El modelo de regresión ajustado permite, una vez calibrado inicialmente, estimar sin sesgo la temperatura sin necesidad de recalibración o reajuste en meses posteriores. En el apartado de validación temporal hemos comprobado cómo el modelo fue capaz de estimar de forma fiable la temperatura durante los tres años siguientes a la calibración inicial con datos únicamente del primer año.

La validación espacial realizada señala que el modelo también es capaz de extender la estimación espacialmente proporcionando valores de temperatura fiables en todas las zonas del embalse cuando el modelo solo ha sido calibrado con mediciones realizadas en un único punto.

En el caso de la turbidez, el estudio previo de los datos de campo disponibles revelaron que éstos no tienen las condiciones requeridas para utilizarlos en el entrenamiento de modelos destinados a inferir de forma indirecta esta variable.

La gran cantidad de datos anómalos observados en las medidas (más del 25 %), los cuales fueron eliminados en el curado realizado, y la fuerte dispersión o incertidumbre que tienen las mismas, superior al 75 % de la medida en muchos casos, hace que estos datos no tengan las condiciones necesarias para entrenar los modelos de deep learning o machine learning.

Para estimar la clorofila-a se optó por entrenar una red neuronal mediante medidas in-situ realizadas de forma simultánea con los pasos de los satélites Sentinel-2A/B. Este modelo también consigue buenos resultados, con un coeficiente de correlación $R^2 = 0,8$ y un error medio de $11 \mu g/l$, tanto en el ajuste como en la clasificación de los datos, en función de su concentración de clorofila-a, en los diferentes niveles de eutrofización.

La red neuronal obtiene buenos resultados en los diferentes tramos de concentración de clorofila-a antes definidos, y es capaz de clasificar bien o muy bien los valores de concentración muy baja, baja y media. Encontramos que el modelo comete una ligera desviación en los valores de alta concentración, pero esta se puede explicar debido a la baja cantidad de datos disponibles en ese rango con los que entrenar el modelo.

La red neuronal también muestra, una gran capacidad para estimar la concentración de clorofila-a sin necesidad de ser reentrenada con el paso del tiempo. En este caso, la red entrenada con los datos disponibles de dos años de mediciones, fue capaz de extender las medidas durante los siguientes dos años.

El modelo presenta también muy buenos resultados en el apartado de coherencia espacial, obteniendo un error medio inferior a los $5 \mu g/l$. Estos resultados demuestran que este modelo permite recuperar la concentración de clorofila-a de toda la superficie del embalse, produciendo mapas de clorofila-a fiables para cualquier punto de la masa de agua.

Esta es una de las fortalezas de este método de monitorización, dado que el seguimiento y la evaluación espacial completa de la superficie del embalse puede llevar a descubrir el punto donde se inician las floraciones o bien las zonas de este que se ven más afectadas. El conocimiento de estas importantes variables por parte de los organismos que gestionan dichas masas de agua, puede ayudar a implementar políticas más eficaces y por lo tanto una mejor gestión de los recursos.

6.2. Debilidades y fortalezas del desarrollo

Se corrigió la sobreestimación observada en las medidas de temperatura calculadas mediante el software ACOLITE gracias un modelo de regresión el cual utiliza las dos bandas térmicas del satélite Landsat 8; Banda 10, 10.60 - 11.19nm y Banda 11, 11.50 - 12.51nm.

La corrección de las desviaciones observadas, y los buenos resultados obtenidos tanto en la validación temporal como en la espacial, muestran cómo un modelo simple, una regresión lineal, es capaz de obtener medidas más precisas de la temperatura y extenderlas tanto en el tiempo como en el espacio con la misma fiabilidad. Por otro lado, si bien se necesitan muy pocos puntos para ajustar el modelo y obtener buenos resultados, este si requiere de una calibración concreta para cada masa de agua a monitorizar.

Se tomó la decisión de corregir las medidas obtenidas por el software ajustando esta regresión debido a la importancia que tiene la monitorización fiable de las altas temperaturas registradas en el agua, ya que éstas tienen una especial influencia en los periodos de eutrofización.

En el caso de inferir la concentración de clorofila se optó por un modelo de inteligencia artificial, como es una red neuronal, capaz de evaluar por completo todo el espectro R_{rs} comprendido entre 400 y 800 nm, utilizando todas así las bandas MSI disponibles del satélite Sentinel-2. Esta es sin duda una de las principales fortalezas de este modelo, ya que este planteamiento toma ventaja frente a los métodos tradicionales los cuales se centran en el desarrollo de índices espectrales y la comparación de la reflectancia observada en ciertas longitudes de onda concretas.

Sin embargo, este planteamiento, al igual que el resto de algoritmos de deep learning, demandan una gran cantidad de datos para entrenar un modelo completamente robusto. En los resultados presentados para la validación temporal también se destaca lo importante que resulta entrenar el modelo con un dataset bien balanceado, en el cual se disponga de muestras al menos comparables en número, para todo el rango de valores que después se pretenda inferir.

6.3. Líneas de continuación futuras

6.3.1. Validación cruzada con medidas en otros embalses

La primera línea de trabajo la podemos encontrar claramente en comprobar cómo de buenos son estos modelos entrenados y estos nuevos algoritmos empleados cuando se generaliza su uso y se emplean varios embalses a la vez, o incluso en masas de agua en las que nunca se hayan entrenado los modelos.

Uno de los problemas más comunes en los algoritmos tradicionales, basados en índices de vegetación y regresiones (ya sean lineales, polinómicas, exponenciales o logarítmicas), es que en todos los casos los coeficientes de ajuste y en mucho casos también los índices, han de ser calculados y calibrados para cada caso de uso, es decir, para embalse, lago o masa de agua continental en la que se quiera trabajar. Las características ópticas y los componentes presentes en el agua son diferentes para cada masa de agua, y esto hasta ahora significaba que los métodos entrenados en un embalse no funcionaban en otro. Los nuevos algoritmos capaces de evaluar por completo el espectro visible R_{rs} comprendido entre 400 y 800 nm, y la capacidad de estos algoritmos de aprender extrayendo la información subyacente de los datos de los que disponen, abren la puerta la puerta a que estos nuevos métodos sean capaces de abstraerse de las condiciones particulares de cada masa de agua y generalizar el problema resultando válidos en cualquier circunstancia.

Se plantea por tanto la primera línea de trabajo en realizar una validación cruzada entrenando el modelo con los datos registrados en un embalse y testeando en otro totalmente independiente del primero. En esta misma línea de actuación también cabe la de entrenar el modelo con datos de los dos embalses y testear también con datos de ambos para comprobar si el modelo se ajusta mejor que entrenando únicamente con uno de ellos.

6.3.2. Nuevo enfoque de los algoritmos de aprendizaje automático en la teledetección

La principal característica y fortaleza de la teledetección la encontramos en su componente espacial, siendo capaz de tomar datos de toda la zona de interés al mismo tiempo, manteniendo por tanto la coherencia espacial existente entre los píxeles. Sin embargo, al calibrar los modelos con medidas discretas tomadas en uno o varios puntos individuales nos olvidamos por completo de esta componente espacial y no se utiliza lo que podría ser la mayor fortaleza de esta técnica.

La segunda línea de trabajo la encontramos por tanto en explotar esta característica con uno de los algoritmos más potentes de los clasificados como algoritmos de deep learning o machine learning, como son las redes neuronales convolucionales. Dichas redes neuronales convolucionales están específicamente diseñadas para explotar las condiciones de las imágenes manteniendo la coherencia y la relación existente entre píxeles, utilizando así la componente espacial de la imagen.

6.4. Sensor para aplicaciones de calidad de agua continentales

En la actualidad no existe ninguna misión operativa dedicada al estudio de la calidad de las aguas continentales mediante teledetección desde satélite. Los satélites para aplicaciones oceanográficas o costeras, como MERIS, MODIS o Sentinel-3, a veces utilizados en masas de agua continentales [109], poseen una resolución espectral y una sensibilidad radiométrica adecuadas, pero su resolución espacial es insuficiente para estudiar la mayoría de los lagos y embalses de tamaño medio o pequeño. Por otro lado, satélites y sensores como los utilizados en el presente trabajo, Landsat 8 y Sentinel-2, orientados a aplicaciones terrestres, pese a contar con una resolución espacial adecuada, factor por el cual se utilizan en este campo, no cuentan con las bandas espectrales ni con la sensibilidad requerida para la teledetección de la calidad del agua.

El objetivo de esta sección es, por tanto, la de recoger lo aprendido durante esta tesis y enumerar las características que un sensor diseñado para el estudio de las aguas continentales debería tener. La monitorización de las masas de agua continentales, debido a su tamaño, y a que la reflectancia en este tipo de aguas es por lo general muy baja, las características que requiere un muestreo de alta fidelidad en este campo se pueden separar en cuatro categorías diferentes: resolución espacial, resolución espectral, calidad radiométrica y resolución temporal.

- **Resolución espacial:** El tamaño, el entorno y la morfología de las masas de agua continentales hacen indispensable una alta resolución espacial, con el objetivo de mapear todas las zonas de estas masas de agua, y captar a pequeña escala la variabilidad en la biodiversidad. Las zonas de cola de los embalses, o las pequeñas ramas que estos puedan tener, son siempre un reto a la hora de monitorizarlas debido a su tamaño, teniendo en cuenta además, que gran parte de las floraciones de algas empiezan en estas zonas de baja profundidad.

Según lo evaluado en este trabajo y también en trabajos anteriores que estudiaron el impacto de la resolución espacial en el mapeo de hábitats costeros acuáticos y de humedales [110] y [111], se llega a la conclusión de que los píxeles de 30 m o menos son ideales, y que los sensores de resolución espacial más gruesos son menos apropiados para mapear y monitorear estas áreas. No es casualidad que los sensores OLI y TIRS del satélite Landsat 8, con resolución espacial de 30 m y el sensor MSI del satélite Sentinel-2 con una resolución de 10, 20 y 60 metros, sean los más utilizados en este campo.

- **Resolución espectral:** La resolución espectral define el detalle con el que se pueden detectar las señales espectrales. Si nos atenemos a los parámetros estudiados en este trabajo, en los capítulos 2 y 3 encontramos las bandas del espectro más interesantes para la monitorización de la calidad del agua, entre las que se incluyen la absorción de clorofila-a a 435 y 675 nm, bandas de absorción de otros pigmentos como el CDOM entre 550 y 900 nm, además de las bandas de fluorescencia de la clorofila y de otros pigmentos situadas a 555 y 690 nm. Otras variables de interés pueden ser la reflectancia de fondo en zonas poco profundas, para el cálculo de batimetrías.

También son necesarias mediciones en el infrarrojo de onda corta (SWIR: 900-2260 nm) para diferenciar de forma precisa las zonas de agua de las zonas de tierra, siendo además estas medidas particularmente necesarias para los algoritmos de corrección atmosférica sobre aguas turbias.

La resolución espectral no sólo se define por la cantidad de bandas en las que mide el satélite, sino que que la resolución y la anchura de estas es también un factor muy importante en la toma de medidas. Los máximos de absorción o reflexión de las diferentes variables ópticamente activas ocurren en rangos espectrales muy estrechos (<20 nm), lo que condiciona la anchura de las bandas espectrales a ~ 10 nm.

En este caso podemos fijarnos en las características del sensor Hyperion, instalado por la NASA en el satélite Earth Observing 1 (EO-1) el cual proporcionaba imágenes con 220 bandas espectrales tomadas entre 400 y 2500 nm con una resolución de 10 nm.

- **Calidad radiométrica:** En masas de aguas continentales, por lo general general aguas turbias, la reflectancia es por lo general muy baja %, lo que exige además de una adecuada corrección atmosférica, una elevada resolución radiométrica y un bajo coeficiente señal/ruido (SNR). Esta reflectancia tan pequeña requiere de una digitalización de 12 bits, por lo que en este caso también podemos tomar como ejemplo las características del sensor MSI del satélite Sentinel-2.
- **Resolución temporal** Como se puede ver en la evolución temporal del pico de clorofila registrado entre julio y agosto de 2020, y presentado en el apartado [5.2.2](#), monitorizar las masas de agua continentales requiere de una alta resolución temporal con el objetivo de captar el comportamiento de este tipo de eventos. Si tenemos además en cuenta la cobertura nubosa, especialmente intensa en este trabajo, la cual se calcula interfiere en el 50 % de las medidas tomadas [\[112\]](#), la resolución temporal debería de ser como máximo de 5 días.

Bibliografía

- [1] I. JOHN E. ESTES (July 21, 1939 - March 9, “The History of Remote Sensing (By John E. Estes 1999, Last Updated 2005).”
- [2] J. R. Irons, M. P. Taylor, and L. Rocchio, “Landsat 1 « Landsat Science,” 2018.
- [3] Instituto Geográfico Nacional and Plan Nacional De Teledetección, “Plan Nacional De Teledetección,” 2018.
- [4] F. Sacristán Romero, “La Teledetección satelital y los sistemas de protección ambiental,” *Civilizar*, vol. 5, no. 9, p. 1, 2005.
- [5] European Spatial Agency (ESA), “ESA - El programa Copérnico.”
- [6] Ariza Alexander, “Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission),” *Centro de Investigación y Desarrollo en información Geográfica del IGAC -CIAF*, p. 46, 2013.
- [7] UN Department of Economics and Social Affairs, “World Population Prospects - Population Division - United Nations,” 2015.
- [8] AEMET, “Proyecciones climáticas para el siglo XXI - Agencia Estatal de Meteorología - AEMET. Gobierno de España,” 2015.
- [9] M. T. M. Álvarez, J. C. G. Gutiérrez, C. Antón-Pacheco, and C. Mediavilla, “Estudio de los humedales y de los usos del suelo en la comarca de Doñana y su gestión mediante técnicas de Teledetección,” tech. rep., instituto geologico y minero, 2007.
- [10] M. T. Sebastián-Frasquet, J. A. Aguilar-Maldonado, E. Santamaría-Del-ángel, and J. Estornell, “Sentinel 2 analysis of turbidity patterns in a coastal lagoon,” *Remote Sensing*, vol. 11, no. 24, pp. 1–17, 2019.

- [11] Instituto Geográfico Nacional and C. N. d. I. Geográfica, “Observación del territorio,” 2021.
- [12] L. W. Fritz, “1993 Annual Report of the International Society for Photogrammetry and Remote Sensing,” tech. rep., International Society for Photogrammetry and Remote Sensing, 1993.
- [13] E. Chuvieco and E. Salinero, *Fundamentos de teledetección espacial*. Manuales universitarios, Rialp, 1996.
- [14] H. Frank, “File:Electromagnetic spectrum -de.svg - Wikimedia Commons,” 2005.
- [15] USGS, “Landsat 7 Science Data Users Handbook Landsat 7 Science Data Users Handbook,” *National Aeronautics and Space Administration*, p. 186, 2011.
- [16] Alonso and U. de Murcia, “Interacción de los elementos de la superficie terrestre con la radiación,” 2006.
- [17] G. Portillo, “Irradiancia,” 2016.
- [18] H. state university, “Introduction to remote sensing,” 2019.
- [19] L. d. S. d. I. G. y. T. d. I. E. B. d. D. (CSIC), “Primeras imágenes del Sentinel-2.”
- [20] N. F. Bravo Morales, “Teledetección Espacial LANDSAT, SENTINEL-2, ASTER L1T y MODIS,” tech. rep., Escuela Profesional de Ingeniería Forestal, 2017.
- [21] S. Ormeño Villajos, “TELEDETECCION FUNDAMENTAL 3ª Edición,” tech. rep., Universidad Politécnica de Madrid, 2006.
- [22] Gis & Beers, “Corrección radiométrica de imágenes satélite,” 2019.
- [23] Gis & Beers, “Cómo corregir el bandeo de imágenes Landsat 7,” 2019.
- [24] Department of the Interior U.S. Geological Survey, “Landsat 8 Data Users Handbook,” Tech. Rep. June, Department of the Interior, U.S. Geological Survey, 2016.
- [25] M. S. Moran, R. D. Jackson, P. N. Slater, and P. M. Teillet, “Evaluation of simplified procedures for retrieval of land surface reflectance factors from satellite sensor output,” *Remote Sensing of Environment*, 1992.

- [26] European Spatial Agency (ESA), “MSI Instrument – Sentinel-2 MSI Technical Guide – Sentinel Online,” 2019.
- [27] European Parliament and Council, “EUR-Lex - 32000L0060 - EN - EUR-Lex,” 2000.
- [28] A. Monteoliva, *Aproximación basada en ciberinfraestructuras remotas y modelado para mejorar la gestión de la eutrofización en lagos y embalses*. PhD thesis, Universidad de Cantabria, 2016.
- [29] D. Romero, “El asqueroso aspecto que presenta el Tajo antes de cruzar a Portugal,” 2019.
- [30] S. R. Carpenter, N. F. Caraco, D. L. Correll, R. W. Howarth, A. N. Sharpley, and V. H. Smith, “Nonpoint pollution of surface waters with phosphorus and nitrogen,” *Ecological Applications*, 1998.
- [31] J. L. Moreno, C. Navarro, and J. De Las Heras, “Propuesta de un índice de vegetación acuática (IVAM) para la evaluación del estado trófico de los ríos de Castilla-La Mancha: Comparación con otros índices bióticos,” *Limnetica*, vol. 25, no. 3, pp. 821–838, 2006.
- [32] G. A. Codd, “Cyanobacterial toxins: Occurrence, properties and biological significance,” *Water Science and Technology*, vol. 32, pp. 149–156, 1 1995.
- [33] H. Caspers, “OECD: Eutrophication of Waters. Monitoring, Assessment and Control. — 154 pp. Paris: Organisation for Economic Co-Operation and Development 1982. (Publié en français sous le titre »Eutrophication des Eaux. Méthodes de Surveillance, d’Evaluation et de Lutte«),” *Internationale Revue der gesamten Hydrobiologie und Hydrographie*, 1984.
- [34] CEDEX, “Usos del agua en función del estado trófico,” 2020.
- [35] K. Barbara, B. György, H. Gerard, and A. Stephan, “Updated CLC illustrated nomenclature guidelines,” *European Environment Agency*, no. 3436, pp. 1–124, 2017.
- [36] L. A. Bartolucci, B. F. Robinson, and L. R. F. Silva, “Field Measurements of the Spectral Response of Natural Waters.,” *Photogrammetric Engineering and Remote Sensing*, vol. 43, no. 5, pp. 595–598, 1977.

- [37] S. K. McFeeters, “The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features,” *International Journal of Remote Sensing*, vol. 17, no. 7, pp. 1425–1432, 1996.
- [38] W. Li, Z. Du, F. Ling, D. Zhou, H. Wang, Y. Gui, B. Sun, and X. Zhang, “A comparison of land surface water mapping using the normalized difference water index from TM, ETM+ and ALI,” *Remote Sensing*, vol. 5, no. 11, pp. 5530–5549, 2013.
- [39] B. C. Ko, H. H. Kim, and J. Y. Nam, “Classification of potential water bodies using landsat 8 OLI and a combination of two boosted random forest classifiers,” *Sensors (Switzerland)*, vol. 15, no. 6, pp. 13763–13777, 2015.
- [40] H. Xu, “Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery,” *International Journal of Remote Sensing*, vol. 27, no. 14, pp. 3025–3033, 2006.
- [41] Z. Du, W. Li, D. Zhou, L. Tian, F. Ling, H. Wang, Y. Gui, and B. Sun, “Analysis of Landsat-8 OLI imagery for land surface water mapping,” *Remote Sensing Letters*, vol. 5, no. 7, pp. 672–681, 2014.
- [42] M. M. El-Hattab, “Change detection and restoration alternatives for the Egyptian Lake Maryut,” *Egyptian Journal of Remote Sensing and Space Science*, vol. 18, no. 1, pp. 9–16, 2015.
- [43] S. Liu, H. Su, G. Cao, S. Wang, and Q. Guan, “Learning from data: A post classification method for annual land cover analysis in urban areas,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 154, pp. 202–215, 8 2019.
- [44] K. Rokni, A. Ahmad, K. Solaimani, and S. Hazini, “A new approach for surface water change detection: Integration of pixel level image fusion and image classification techniques,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 34, no. 1, pp. 226–234, 2015.
- [45] W. Asfaw, A. T. Haile, and T. Rientjes, “Combining multisource satellite data to estimate storage variation of a lake in the Rift Valley Basin, Ethiopia,” *International*

- Journal of Applied Earth Observation and Geoinformation*, vol. 89, no. February, p. 102095, 2020.
- [46] Y. Du, Y. Zhang, F. Ling, Q. Wang, W. Li, and X. Li, “Water bodies’ mapping from Sentinel-2 imagery with Modified Normalized Difference Water Index at 10-m spatial resolution produced by sharpening the swir band,” *Remote Sensing*, vol. 8, no. 4, 2016.
- [47] C. Hu, F. E. Muller-Karger, C. Taylor, K. L. Carder, C. Kelble, E. Johns, and C. A. Heil, “Red tide detection and tracing using MODIS fluorescence data: A regional example in SW Florida coastal waters,” *Remote Sensing of Environment*, vol. 97, no. 3, pp. 311–321, 2005.
- [48] S. Sathyendranath, “Reports of the International Ocean-Colour Coordinating Group Remote Sensing of Ocean Colour in Coastal , and Other Optically-Complex , Waters,” *Reports and Monographs of the International OceanColour Coordinating Group*, vol. 3, no. January 2000, pp. 1–145, 2000.
- [49] M. W. Matthews, “A current review of empirical procedures of remote sensing in Inland and near-coastal transitional waters,” 2011.
- [50] T. Akbar, Q. Hassan, and G. Achari, “A Remote sensing based framework for predicting water quality of different source waters,” *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 34, 2010.
- [51] M. Elhag, I. Gitas, A. Othman, J. Bahrawi, and P. Gikas, “Assessment of water quality parameters using temporal remote sensing spectral reflectance in arid environments, Saudi Arabia,” *Water (Switzerland)*, vol. 11, no. 3, 2019.
- [52] A. Ruiz-Verdú, E. De Miguel, C. Robles-González, and a. Fernández-Renau, “CINCLUS: un instrumento para la teledetección de las aguas continentales,” *Teledetección: Agua y desarrollo sostenible. XIII Congreso de la Asociación Española de Teledetección*, pp. 109–112, 2009.
- [53] C. D. Mobley, “Light and Water: Radiative transfer in natural waters (vol. 592),” *Ligth and Water : Radiative Transfer in Natural Waters*, no. January 1994, p. 554, 1994.

- [54] S. Lavender, “Remote Sensing of Coastal Aquatic Environments-Technologies, Techniques and Applications.,” *The Photogrammetric Record*, vol. 21, no. 114, pp. 181–181, 2006.
- [55] J. Kirk, *Light and Photosynthesis in Aquatic Ecosystems*. Cambridge University Press, 2010.
- [56] H. W. Siegelman, “Photosynthetic Pigments of Algae. Kingsley S. Rowan ,” *The Quarterly Review of Biology*, vol. 65, no. 3, 1990.
- [57] J. Gregor and B. Maršálek, “Freshwater phytoplankton quantification by chlorophyll a: A comparative study of in vitro, in vivo and in situ methods,” *Water Research*, vol. 38, no. 3, pp. 517–522, 2004.
- [58] A. M. Pinto, E. Von Sperling, and R. M. Moreira, “Chlorophyll-a determination via continuous measurement of plankton fluorescence: Methodology development,” *Water Research*, vol. 35, no. 16, pp. 3977–3981, 2001.
- [59] M. Babin, C. S. Roesler, and J. J. Cullen, *Real-time coastal observing systems for marine ecosystem dynamics and harmful algal blooms : theory, instrumentation and modelling*. Unesco Paris, France, 2008.
- [60] J. Blaustein, “The peak near 700 nm on radiance spectra of algae and water: Relationships of its magnitude and position with chlorophyll,” *International Journal of Remote Sensing*, vol. 13, no. 17, pp. 3367–3373, 1992.
- [61] J. Jensen, *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall series in geographic information science, Pearson Prentice Hall, 2007.
- [62] J. E. O’Reilly, S. Maritorena, B. G. Mitchell, D. A. Siegel, K. L. Carder, S. A. Garver, M. Kahru, and C. McClain, “Ocean color chlorophyll algorithms for SeaWiFS,” *Journal of Geophysical Research: Oceans*, vol. 103, no. C11, pp. 24937–24953, 1998.
- [63] F. L. Hellweger, P. Schlosser, U. Lall, and J. K. Weissel, “Use of satellite imagery for water quality studies in New York Harbor,” *Estuarine, Coastal and Shelf Science*, vol. 61, no. 3, pp. 437–448, 2004.

- [64] G. Mancino, A. Nolè, V. Urbano, M. Amato, and A. Ferrara, “Assessing water quality by remote sensing in small lakes: The case study of Monticchio lakes in southern Italy,” *IForest*, vol. 2, no. 7, pp. 154–161, 2009.
- [65] J. F. Gower, R. Doerffer, and G. A. Borstad, “Interpretation of the 685nm peak in water-leaving radiance spectra in terms of fluorescence, absorption and scattering, and its observation by MERIS,” *International Journal of Remote Sensing*, vol. 20, no. 9, pp. 1771–1786, 1999.
- [66] I. Reche, “Sensibilidad de los ecosistemas acuáticos a la radiación ultravioleta: el papel de la materia orgánica disuelta,” *Ecosistemas*, vol. XII, no. 1, pp. 1–11, 2003.
- [67] C. A. Corbett, “Scholar Commons Reports Tampa Bay Area Study Group Project Colored Dissolved Organic Matter (CDOM) Workshop summary,” in *Colored Dissolved Organic Matter (CDOM)*, (PUNTA GORDA, FLORIDA), Charlotte Harbor National Estuary Program, 2007.
- [68] J. Delegido, P. Urrego, E. Vicente, X. Sòria-Perpinyà, J. Soria, M. Pereira-Sandoval, A. Ruiz-Verdú, R. Peña, and J. Moreno, “Turbidez y profundidad de disco de Secchi con Sentinel-2 en embalses con diferente estado trófico en la Comunidad Valenciana,” *Revista de Teledetección*, no. 54, p. 15, 2019.
- [69] B. P. Page, L. G. Olmanson, and D. R. Mishra, “A harmonized image processing workflow using Sentinel-2/MSI and Landsat-8/OLI for mapping water clarity in optically variable lake systems,” *Remote Sensing of Environment*, vol. 231, no. 9, p. 111284, 2019.
- [70] Z. P. Lee, S. Shang, C. Hu, K. Du, A. Weidemann, W. Hou, J. Lin, and G. Lin, “Secchi disk depth: A new theory and mechanistic model for underwater visibility,” *Remote Sensing of Environment*, vol. 169, pp. 139–149, 2015.
- [71] V. I. Okulov, E. A. Pamyatnykh, and V. P. Silin, “On the theoretical description of low-temperature effects in metals and doped semiconductors on the basis of the quantum theory of an electron liquid,” *Low Temperature Physics*, vol. 35, 2009.

- [72] B. Tardy, V. Rivalland, M. Huc, O. Hagolle, S. Marcq, and G. Boulet, “A software tool for atmospheric correction and surface temperature estimation of Landsat infrared thermal data,” *Remote Sensing*, 2016.
- [73] C. J. Donlon and I. S. Robinson, “Radiometric validation of ERS-1 along-track scanning radiometer average sea surface temperature in the atlantic ocean,” *Journal of Atmospheric and Oceanic Technology*, vol. 15, no. 3, pp. 647–660, 1998.
- [74] D. E. V. Pedrós, “SEGUIMIENTO DE EMBALSES 2018,” tech. rep., CONFEDERACIÓN HIDROGRÁFICA DEL EBRO, 2018.
- [75] D. E. V. Pedrós, “SEGUIMIENTO DE EMBALSES 2019,” tech. rep., CONFEDERACIÓN HIDROGRÁFICA DEL EBRO, 2019.
- [76] T. S. Agustín Monteoliva, Alberto Criado, José Augusto Monteoliva, “ESTUDIO DEL ESTADO TRÓFICO DEL EMBALSE DE EL VAL (ZARAGOZA) Y PROGRAMA DE MEDIDAS,” tech. rep., CONFEDERACIÓN HIDROGRÁFICA DEL EBRO, 2017.
- [77] D. C. Harris, “Análisis Químico Cuantitativo 2^a edición, Ed. Reverte,” *Técnicas Avanzadas en Química*, 2004.
- [78] N. Abril Díaz, J. Antonio Bárcena Ruiz, E. Fernández Reyes, A. Galván Cejudo, J. Jorrín Novo, J. Peinado Peinado, F. Toribio Meléndez-Valdés, and I. Túnez Fiñana, “8. Espectrofometría: Espectros de absorción y cuantificación colorimétrica de biomoléculas,” tech. rep., Departamento de Bioquímica y Biología Molecular, Universidad de Córdoba, 2015.
- [79] D. Rodríguez-Esparragón, *Evaluación y desarrollo de métricas de calidad espacial y espectral para aplicaciones de fusión de imágenes multispectrales de teledetección de alta resolución*. PhD thesis, Las Palmas de Gran Canaria, 2015.
- [80] K. Kpalma, M. Chikr El-Mezouar, and N. Taleb, “Recent Trends in Satellite Image Pan-sharpening techniques,” in *1st International Conference on Electrical, Electronic and Computing Engineering*, p. 10, 2014.

-
- [81] I. Amro, J. Mateos, M. Vega, R. Molina, and A. K. Katsaggelos, “A survey of classical methods and new trends in pansharpening of multispectral images,” 2011.
- [82] J. Zhang, “Multi-source remote sensing data fusion: Status and trends,” 2010.
- [83] P. S. Chavez, S. C. Sides, and J. A. Anderson, “Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic,” 1991.
- [84] C. Pohl and J. L. Van Genderen, “Review article Multisensor image fusion in remote sensing: Concepts, methods and applications,” 1998.
- [85] M. Lillo-Saavedra, C. Gonzalo, A. Arquero, and E. Martinez, “Fusion of multispectral and panchromatic satellite sensor imagery based on tailored filtering in the Fourier domain,” *International Journal of Remote Sensing*, vol. 26, no. 6, pp. 1263–1268, 2005.
- [86] G. Hong and Y. Zhang, “Comparison and improvement of wavelet-based image fusion,” *International Journal of Remote Sensing*, vol. 29, no. 3, pp. 673–691, 2008.
- [87] K. Amolins, Y. Zhang, and P. Dare, “Wavelet based image fusion techniques - An introduction, review and comparison,” 2007.
- [88] F. Palsson, J. R. Sveinsson, and M. O. Ulfarsson, “Sentinel-2 image fusion using a deep residual network,” *Remote Sensing*, vol. 10, no. 8, p. 1290, 2018.
- [89] C. Lanaras, J. Bioucas-Dias, S. Galliani, E. Baltsavias, and K. Schindler, “Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 146, pp. 305–319, 2018.
- [90] B. Lim, S. Son, H. Kim, S. Nah, and K. M. Lee, “Enhanced Deep Residual Networks for Single Image Super-Resolution,” *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, vol. 2017-July, pp. 1132–1140, 2017.
- [91] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” *arXiv*, 2015.

- [92] G. Kaplan, “Sentinel-2 Pan Sharpening—Comparative Analysis,” *Proceedings*, vol. 2, p. 345, mar 2018.
- [93] L. Wald, “Quality of high resolution synthesised images: Is there a simple criterion ?,” *Third conference "Fusion of Earth data: merging point measurements, raster maps and remotely sensed images*, no. 1, pp. 99–103, 2000.
- [94] F. M. Acosta, F. E. González, and J. M. Ruiz, “Tutorial de Teledetección Espacial,” tech. rep., Universidad de Las Palmas de Gran Canaria, 2013.
- [95] M. A. Gilabert, C. Conese, and F. Maselli, “An atmospheric correction method for the automatic retrieval of surface reflectances from tm images,” *International Journal of Remote Sensing*, vol. 15, no. 10, pp. 2065–2086, 1994.
- [96] P. S. Chavez, “An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data,” *Remote Sensing of Environment*, vol. 24, no. 3, pp. 459–479, 1988.
- [97] C. Brockmann, R. Doerffer, M. Peters, K. Stelzer, S. Embacher, and A. Ruescas, “Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters,” in *European Space Agency, (Special Publication) ESA SP*, vol. SP-740, European Space Agency, 2016.
- [98] Q. Vanhellemont and K. Ruddick, “Acolite for Sentinel-2: Aquatic applications of MSI imagery,” *European Space Agency, (Special Publication) ESA SP*, vol. SP-740, no. May, pp. 9–13, 2016.
- [99] Q. Vanhellemont and K. Ruddick, “Atmospheric correction of metre-scale optical satellite data for inland and coastal water applications,” *Remote Sensing of Environment*, vol. 216, no. July, pp. 586–597, 2018.
- [100] Q. Vanhellemont, “Automated water surface temperature retrieval from Landsat 8/TIRS,” *Remote Sensing of Environment*, vol. 237, no. October 2019, p. 111518, 2020.

-
- [101] F. Eugenio, J. Marcello, and 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, no. 7, pp. 3539–3549, 2015.
- [102] H. W. Paerl, “Mitigating harmful cyanobacterial blooms in a human- and climatically-impacted world,” *Life*, vol. 4, no. 4, pp. 988–1012, 2014.
- [103] R. M. Cox, R. D. Forsythe, G. E. Vaughan, and L. L. Olmsted, “Assessing water quality in catawba river reservoirs using landsat thematic mapper satellite data,” *Lake and Reservoir Management*, vol. 14, no. 4, pp. 405–416, 1998.
- [104] R. J. Brewin, D. A. Smale, P. J. Moore, G. Dall’Olmo, P. I. Miller, B. H. Taylor, T. J. Smyth, J. R. Fishwick, and M. Yang, “Evaluating operational AVHRR sea surface temperature data at the coastline using benthic temperature loggers,” *Remote Sensing*, vol. 10, no. 6, 2018.
- [105] B. A. Schaeffer, J. Iames, J. Dwyer, E. Urquhart, W. Salls, J. Rover, and B. Seegers, “An initial validation of Landsat 5 and 7 derived surface water temperature for U.S. lakes, reservoirs, and estuaries,” *International Journal of Remote Sensing*, vol. 39, no. 22, pp. 7789–7805, 2018.
- [106] N. Pahlevan, B. Smith, J. Schalles, C. Binding, Z. Cao, R. Ma, K. Alikas, K. Kangro, D. Gurlin, N. Hà, B. Matsushita, W. Moses, S. Greb, M. K. Lehmann, M. Ondrusek, N. Oppelt, and R. Stumpf, “Seamless retrievals of chlorophyll-a from Sentinel-2 (MSI) and Sentinel-3 (OLCI) in inland and coastal waters: A machine-learning approach,” *Remote Sensing of Environment*, vol. 240, no. August 2019, p. 111604, 2020.
- [107] W. Yang, B. Matsushita, J. Chen, and T. Fukushima, “Estimating constituent concentrations in case II waters from MERIS satellite data by semi-analytical model optimizing and look-up tables,” *Remote Sensing of Environment*, vol. 115, no. 5, pp. 1247–1259, 2011.
- [108] Y. Woo Kim, T. H. Kim, J. Shin, D. S. Lee, Y. S. Park, Y. Kim, and Y. K. Cha, “Validity evaluation of a machine-learning model for chlorophyll a retrieval using

- Sentinel-2 from inland and coastal waters,” *Ecological Indicators*, vol. 137, no. December 2021, p. 108737, 2022.
- [109] J. Kravitz, M. Matthews, S. Bernard, and D. Griffith, “Application of Sentinel 3 OLCI for chl-a retrieval over small inland water targets: Successes and challenges,” *Remote Sensing of Environment*, vol. 237, 2020.
- [110] K. R. Turpie, V. V. Klemas, K. Byrd, M. Kelly, and Y. H. Jo, “Prospective HypsIRI global observations of tidal wetlands,” *Remote Sensing of Environment*, vol. 167, pp. 206–217, 2015.
- [111] N. Pahlevan, S. Sarkar, and B. A. Franz, “Uncertainties in coastal ocean color products: Impacts of spatial sampling,” *Remote Sensing of Environment*, vol. 181, no. 443, pp. 14–26, 2016.
- [112] M. Mercury, R. Green, S. Hook, B. Oaida, W. Wu, A. Gunderson, and M. Chodas, “Global cloud cover for assessment of optical satellite observation opportunities: A HypsIRI case study,” *Remote Sensing of Environment*, vol. 126, pp. 62–71, 2012.
- [113] G. Blanchet and M. Charbit, *Digital Signal and Image Processing using MATLAB®*. Wiley-ISTE (22 Mayo 2006), 2013.
- [114] R. Haydn, G. W. Dalke, J. Henkel, and J. E. Bare, “Application of the Ihs Color Transform To the Processing of Multisensor Data and Image Enhancement.,” in *Proceedings of the International Symposium on Remote Sensing of Environment*, pp. 599–616, 1982.
- [115] R. Welch and M. Ehlers, “Merging Multiresolution Spot Hrv and Landsat Tm Data.,” *Photogrammetric Engineering and Remote Sensing*, vol. 53, no. 3, pp. 301–303, 1987.
- [116] W. A. Hallada and S. Cox, “Image Sharpening for Mixed Spatial and Spectral Resolution Satellite Systems.,” in *Proceedings of the International Symposium on Remote Sensing of Environment*, vol. 3, pp. 1023–1032, 1983.
- [117] F. C. García and F. A. Sarria, “Comparación de técnicas de fusión en imágenes de alta resolución espacial,” *Geofocus*, 2014.

- [118] S. G. Mallat, “A Theory for Multiresolution Signal Decomposition: The Wavelet Representation,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674–693, 1989.
- [119] R. G. A. Seco, “Fusión de imágenes multispectrales y pancromáticas : nuevas alternativas metodológicas basadas en las transformaciones wavelet discretas empleando el algoritmo de Mallat,” *Revista de Teledetección*, vol. 18, pp. 63–73, 2002.
- [120] T. Ranchin and L. Wald, “Fusion of high spatial and spectral resolution images: The ARSIS concept and its implementation,” 2000.

Anexos

Anexo A: Algoritmos de Fusión

Intensidad-matiz-saturación, IHS

Se parte de la idea de que, al igual que el color de una imagen se puede expresar a partir de sus componentes R,G y B, este también se puede expresar a partir de su intensidad (I), matiz (H) y saturación (S). La base de esta técnica reside en el hecho de que las transformaciones IHS logran desacoplar la información espectral de la imagen, la cual queda representada en las componentes H y S de la imagen transformada, de la información espacial, la cual se queda aislada en la componente I [84].

Se asignan, por tanto, tres bandas MS a los diferentes canales RGB y se transforman a los componentes IHS. Debido a que después de la transformación, el canal de intensidad aísla gran parte de la información espacial de las imágenes multiespectrales, este se puede sustituir por la banda pancromática de alta resolución y realizar el proceso de transformación inversa volviendo a los canales RGB. Antes de realizar el proceso de transformación inversa, es necesario ajustar el histograma de la imagen pancromática al histograma de la componente I con el objetivo de que estos tengan la misma media y desviación estándar.

Por último, se realiza la transformación inversa de IHS para obtener los nuevos canales RGB.

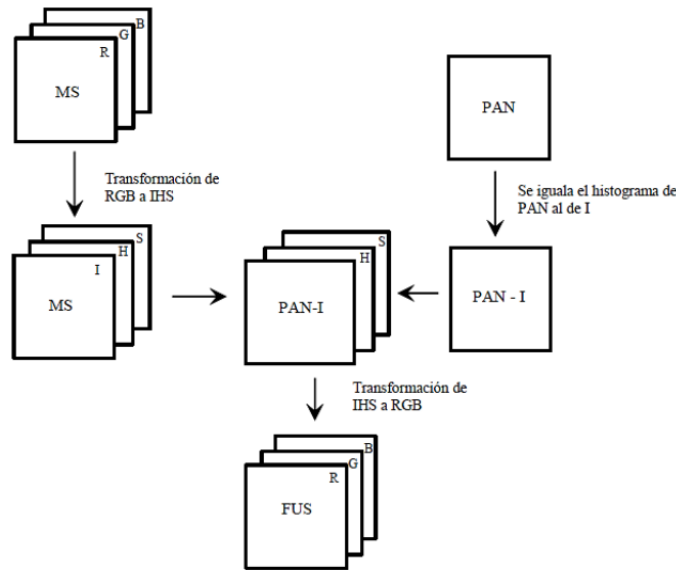


Figura 6.1: Diagrama del algoritmo de fusión IHS [79]

Las diferentes transformaciones se realizan mediante las siguientes matrices de transformación. Estas matrices están sujetas a cambios en función de los diferentes autores, ya que cada uno de ellos calcula la componente I de una forma distinta [113, 114, 115].

$$\begin{pmatrix} I \\ \nu_1 \\ \nu_2 \end{pmatrix} = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{-\sqrt{2}}{6} & \frac{-\sqrt{2}}{6} & \frac{2\sqrt{2}}{6} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 0 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (6.1)$$

$$\begin{pmatrix} R' \\ G' \\ B' \end{pmatrix} = \begin{pmatrix} 1 & \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & \frac{-1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} \\ 1 & \sqrt{2} & 0 \end{pmatrix} \begin{pmatrix} PAN \\ \nu_1 \\ \nu_2 \end{pmatrix} \quad (6.2)$$

Método de Brovey

En la transformación original, la ecuación utiliza las bandas roja, verde, azul (RGB) y la banda pancromática como entradas, para producir nuevas bandas roja, verde y azul. Antes de realizar las operaciones algebraicas es necesario normaliza cada una de las bandas de la composición RGB.

Así, la transformada de Brovey inicial puede ser implementada según la expresión matemática [116]:

$$ND_{(R,G,B)f} = \frac{3 \cdot ND_{(R,G,B)}}{ND_R + ND_G + ND_B} \cdot PAN \quad (6.3)$$

donde $ND_{R,G,B}$ son los niveles digitales de cada píxel en las bandas asignadas al Rojo, Verde y Azul, y PAN, los niveles digitales de cada píxel de la imagen pancromática.

Esta transformación también es aplicable a imágenes de n bandas, quedando la ecuación siguiente:

$$ND_{i,f} = \frac{n \cdot ND_i}{ND_1 + ND_2 + \dots + ND_n} \cdot PAN \quad (6.4)$$

Filtro Paso alto, HPF

Este método consiste en extraer la información espacial de la imagen pancromática aislando las componentes de alta frecuencia mediante filtros de paso alto, y añadir esa información espacial a la información multiespectral de menor resolución espacial mediante operaciones de álgebra de mapas [84].

El algoritmo se puede resumir en tres pasos.

1. Aplicar el filtro de paso alto (6.5): El objetivo al aplicar el filtro de paso alto es aislar los componentes de alta frecuencia de la imagen, atenuando las bajas frecuencias. En términos prácticos, esto implica un realce de los contornos de los objetos o rasgos lineales presentes en la imagen.

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad (6.5)$$

El tamaño y el valor central del filtro, se tiene que calcular en función de R, que se define como:

$$R = \frac{r_{MS}}{r_P} \quad (6.6)$$

donde r_{MS} y r_p son las resoluciones espaciales de las bandas multiespectrales y pancromática respectivamente.

Valor R	Tamaño kernel	Valor Central		
		Valor por defecto	Valores Opcionales	
1 <R <2.5	5 x 5	24	28	32
2.5 <R <3.5	7 x 7	48	56	64
3.5 <R <5.5	9 x 9	80	93	106
5.5 <R <7.5	11 x 11	120	150	180
7.5 <R <9.5	13 x 13	168	210	252
R <9.5	15 x 15	336	392	448

Tabla 6.1: Tamaño y valor central de la matriz de filtro en función de R [117].

2. Añadir la información extraída de la imagen pancromática filtrada a cada banda de la imagen multiespectral.

Previo a realizar este proceso se deben reescalar las bandas MS a la misma resolución que la banda PAN. A continuación, para añadir la información extraída de la imagen filtrada a las imágenes MS, se introduce un factor de ponderación W puede ser calculado mediante la fórmula:

$$W = \left(\frac{\sigma_{MS}}{\sigma_{hpf}} \right) * M \quad (6.7)$$

que depende de M (que a su vez depende también de R) y de la desviación típica tanto de la imagen filtrada como de la banda multiespectral. W

donde σ_{MS} y σ_{hpf} son las desviaciones típicas de cada una de las bandas multiespectrales y de la imagen filtrada respectivamente, y M es un parámetro que determina la intensidad en la aplicación del filtro. M se puede calcular en función del ratio de las imágenes a partir de la tabla [6.2](#)

Valor R	Valor de M		
	Máximo	Por defecto	Mínimo
1 <R <2.5	0.30	0.25	0.20
2.5 <R <3.5	0.65	0.50	0.35
3.5 <R <5.5	0.65	0.50	0.35
5.5 <R <7.5	1.0	0.65	0.50
7.5 <R <9.5	1.4	1.0	0.65
R <9.5	2.0	1.35	1.0

Tabla 6.2: Valores correspondientes al parámetro M en función del valor del ratio R [117](#)

El último cálculo es el de las bandas fusionadas, las cuales vienen dadas por una combinación lineal:

$$P_{out} = P_{input} + [P_{HPF} * W] \quad (6.8)$$

donde P_{out} es cada píxel de la imagen fusionada; P_{input} es cada píxel de la imagen multiespectral reescalada; y, el segundo término es un producto escalar con P_{HPF} como la imagen pancromática filtrada y W el factor de ponderación.

3. Expansión Lineal del Histograma.

El último procedimiento consiste en ajustar la imagen resultante del paso 2, de forma que la media y la desviación típica coincidan con las de la imagen original.

Transformada discreta de Wavelet

– Algoritmo de Mallat

El análisis multirresolución se basa en la teoría según la cual el análisis de una imagen y la identificación de patrones es más eficiente si la imagen es analizada a diferentes niveles de resolución. Estos algoritmos permiten descomponer datos bidimensionales en componentes de distinta frecuencia y estudiar cada componente a una resolución acorde con su escala.

La base del algoritmo de Mallat [118] descompone, por tanto, la imagen original en una imagen de aproximación de menos resolución espacial y unos coeficientes de detalle vertical, horizontal y diagonal.

Para ello, el algoritmo emplea dos filtros unidimensionales, llamados filtros de cuadratura, uno de paso bajo ('h') y otro de paso alto ('g'), seguidos de operaciones de muestreo. El filtro paso bajo, asociado con las funciones de escalamiento, permite el análisis de datos de baja frecuencia. El filtro de paso alto, asociado con las funciones Wavelet, permite el análisis de los componentes de alta frecuencia.

El número de parámetros de estos filtros y el valor de estos parámetros depende de la función Wavelet empleada en el análisis. Una de las bases más utilizada es Daubechies con cuatro coeficientes (DB4) [119]:

$$h : \left\{ \frac{(1 - \sqrt{3})}{4\sqrt{2}}, \frac{(3 - \sqrt{3})}{4\sqrt{2}}, \frac{(3 + \sqrt{3})}{4\sqrt{2}}, \frac{1 + \sqrt{3}}{4\sqrt{2}} \right\} \quad (6.9)$$

$$g : \left\{ \frac{(1 + \sqrt{3})}{4\sqrt{2}}, \frac{(3 + \sqrt{3})}{4\sqrt{2}}, \frac{(3 - \sqrt{3})}{4\sqrt{2}}, \frac{1 - \sqrt{3}}{4\sqrt{2}} \right\} \quad (6.10)$$

Las funciones base de la transformada Wavelet $\psi_{a,b}(x)$, "las familias wavelets", son dilataciones y transformaciones de la Wavelet madre $\psi(x)$.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi \left(\frac{x - b}{a} \right) \quad (6.11)$$

donde a y b $\in \mathbb{R}$ son el factor de dilatación y el factor de traslación.

Como resultado de estas transformaciones se obtienen cuatro nuevas imágenes de menor resolución que la imagen original. La primera, la imagen de aproximación, contiene la información espectral de la imagen original, y las otras tres restantes, los coeficientes de detalle, recogen la información espacial (horizontal, vertical y diagonal) que la imagen pierde al pasar de la resolución original a la mitad de resolución. A partir de estas cuatro nuevas imágenes se puede reconstruir exactamente la imagen original.

Para poder entender el análisis multiresolución basado en el algoritmo de mallat, aplicado a datos bidimensionales, es muy útil imaginar la transformada Wavelet como una pirámide: la base de la pirámide representa la imagen original, con 'f' filas y 'c' columnas. En cada nivel de la pirámide, al que se accede desde el nivel inmediatamente inferior, se tiene una aproximación de la imagen original con resoluciones más gruesas. Se cumple que en cada nivel N la imagen aproximación tiene $f/2^N$ filas y $c/2^N$ columnas.




Figura 6.2: Representación piramidal del algoritmo de Mallat [79].

Por lo general, la estrategia seguida es la sustitutiva (figura 6.3), donde el algoritmo de fusión consiste en aplicar la transformada wavelet a las imágenes PAN y MS para obtener la imagen de aproximación y los coeficientes de detalle correspondientes y a continuación aplicar la transformada inversa para reconstruir la imagen con la imagen de aproximación de la imagen MS y los coeficientes de detalle de la PAN.

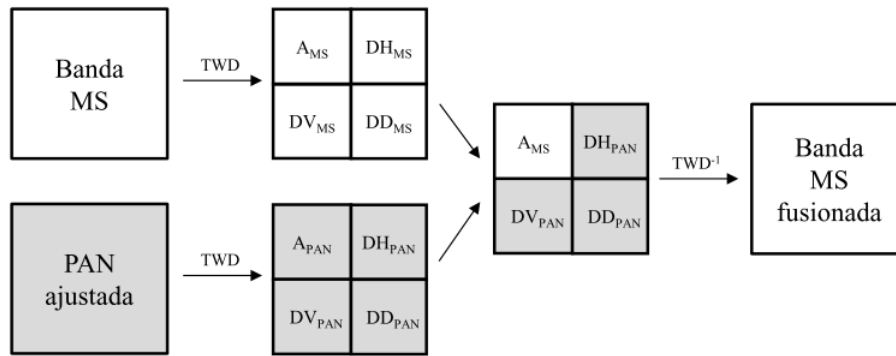


Figura 6.3: Estrategia de fusión sustitutiva usando el algoritmo de Mallat [79].

Pero la baja direccionalidad del proceso de filtrado presenta como principal problema la aparición del efecto diente de sierra, el cual deteriora notablemente la calidad de las imágenes fusionadas. En este estudio se ha empleado una técnica derivada de el algoritmo de mallat, que se conoce como el Método Wavelet Sustitutivo IHS (figura 6.4).

- Método wavelet aditivo IHS usando el algoritmo de mallat

Este método es muy similar al explicado anteriormente, pero primero se aplica la transformación IHS (primer algoritmo explicado de este sección) a tres bandas multiespectrales, y se aplica el algoritmo de mallat a la imagen de intensidad y a la pancromática. De esta forma se aplica el mismo nivel de descomposición a ambas imágenes, y se extraen las imágenes de aproximación y los coeficientes de detalle espacial. Por último se utiliza la imagen de aproximación de la imagen de intensidad y los coeficientes de la banda PAN para realizar la transformada inversa.

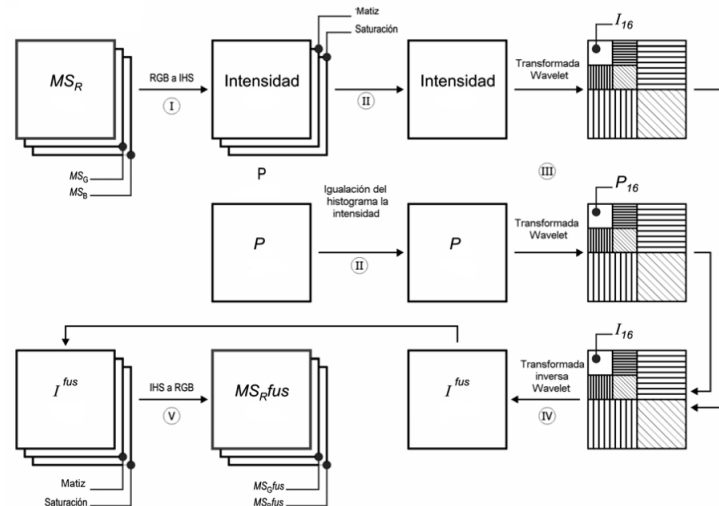


Figura 6.4: Esquema del método Wavelet aditivo intensidad-matiz-saturación usando el algoritmo de Mallat [79].

Al igual que en los otros métodos de fusión, y con el objetivo de que los coeficientes de detalle tengan una información espectral lo más parecida posible, antes de aplicar la transformación inversa, generalmente se ajustan los histogramas de la PAN al de la imagen I.

Anexo B: Índices para evaluación la fusión de imágenes

ERGAS espectral

Propuesto para comparar la calidad espectral de las imágenes, este índice puede expresarse mediante la ecuación:

$$ERGAS_{espectral} = 100 \frac{h}{l} \sqrt{\frac{1}{N_{bandas}} \sum_{i=1}^{N_{bandas}} \left[\frac{(RMSE_{espectral}(Banda_i))^2}{(MULTI_i)^2} \right]} \quad (6.12)$$

donde h y l representan las resoluciones espaciales de las imágenes pancromática y multiespectral respectivamente, N_{bandas} es el número de bandas multiespectrales fusionadas, $MULTI_i$ es el valor medio de la radiancia espectral de la banda i -ésima. $RMSE_{espectral}$ es el error cuadrático medio, que se define como:

$$RMSE_{espectral}(Banda_i) = \sqrt{\frac{\sum_{j=1}^{NP} (MULTI_i(j) - FUS_i(j))^2}{NP}} \quad (6.13)$$

donde NP es el número de píxeles que componen la imagen, y $MULTI_i$ y FUS_i son las imágenes multiespectrales originales y fusionadas, respectivamente.

El índice ERGAS toma valores cercanos a 0 cuando se incrementa la calidad del producto fusionado. Valores menores que 3, indican una buena calidad de la imagen fusionada [120], tanto mejor cuanto se acerca a cero.

ERGAS espacial

Dado que el anterior índice ERGAS solamente considera las características espectrales de la imagen, en 2005 se presenta un nuevo índice espacial, denominado índice ERGAS espacial, que introduce un RMSE espacial [85]:

$$ERGAS_{espacial} = 100 \frac{h}{l} \sqrt{\frac{1}{N_{bandas}} \sum_{i=1}^{N_{bandas}} \left[\frac{(RMSE_{espacial}(Banda_i))^2}{(PAN_i)^2} \right]} \quad (6.14)$$

$$RMSE_{espacial}(Banda_i) = \sqrt{\frac{\sum_{j=1}^{NP} (PAN_i(j) - FUS_i(j))^2}{NP}} \quad (6.15)$$

donde PAN_i es la imagen obtenida al ajustar el histograma de la imagen pancromática original al histograma de la banda i -ésima de la imagen multiespectral.

Anexo C: Resultados de la fusión de imágenes para el satélite Landsat 8

El satélite Landsat 8, tal y como se presentó en la tabla [1.1](#), toma imágenes que constan de 11 bandas espectrales divididas en 3 resoluciones diferentes: 1 banda pancromática de 15 m de resolución (Banda 8), 8 bandas espectrales de 30 m (bandas 1-7 y 9, y dos bandas térmicas tomadas por el sensor OLI a 100 m (Bandas 10 y 11). Las bandas térmicas se remuestrean a 30 m antes de que los datos se presenten y publiquen en abierto, pero su resolución original es de 100 m.

A diferencia del satélite Sentinel-2, Landsat 8 si dispone de una banda pancromática definida con la que realizar el proceso de fusión, la banda 8 (con una resolución de 15 m), por lo que esa es la banda a utilizar con los algoritmos de fusión tradicionales.

Cabe mencionar también que, al igual que en el caso anterior, todos los métodos de fusión utilizados han sido optimizados y detallados en la medida de lo posible, de forma que los resultados puedan ser interpretados y extrapolados para la fusión de cualquier otra imagen. De hecho, para este estudio también se han empleado cinco imágenes diferentes de cinco países diferentes. Las imágenes escogidas se corresponden con las mismas regiones geográficas utilizadas en el análisis del satélite Sentinel-2.




Figura 6.5: Imágenes del satélite Landsat 8 utilizadas en las evaluaciones cualitativa y cuantitativa de los métodos de fusión analizados.

– Evaluación Cualitativa

Al igual que en el análisis cualitativo realizado para el satélite Sentinel-2, para este apartado se han elaborado diferentes mosaicos (figuras [6.6](#) a [6.11](#)), con los que se pretenden evaluar criterios tales como el color y el aspecto de las imágenes, o el detalle espacial y la nitidez de los bordes, etc. Los mosaicos están compuestos por algunas de las bandas más representativas de las imágenes con las que se ha trabajado. En esta ocasión se ha escogido la imagen correspondiente a España para realizar la evaluación cualitativa.

Las primeras figuras (6.6 a 6.9) tratan de mostrar la coherencia espectral que las bandas fusionadas mantienen con las bandas originales, es decir, las diferencias de color que se hayan podido producir en la imagen durante el proceso de fusión. Se muestran por tanto, las bandas originales y las fusionadas en las cuales se han marcado las zonas de la imagen con mayor diferencia espectral, o lo que es lo mismo, las zonas que han sufrido un mayor cambio en el color durante el proceso de fusión. También se muestran en estas imágenes, los histogramas producidos al restar la banda original de la banda fusionada mediante el método CNN, por lo que en los histogramas se representan las distribuciones de las diferencias entre ambas bandas.

Al igual que en el caso anterior, todas las imágenes se presentan en escala de grises, escaladas a enteros de 16 bits, 2^{16} niveles de gris, igual que las bandas originales de Landsat 8. En este caso, en las imágenes de los mosaicos se han marcado todos los píxeles encontrados con una diferencia mayor a 2000 niveles digitales.





Figura 6.6: Banda 2 del satélite Landsat 8 frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.





Figura 6.7: Banda 3 del satélite Landsat 8 frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.





Figura 6.8: Banda 4 del satélite Landsat 8 frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.

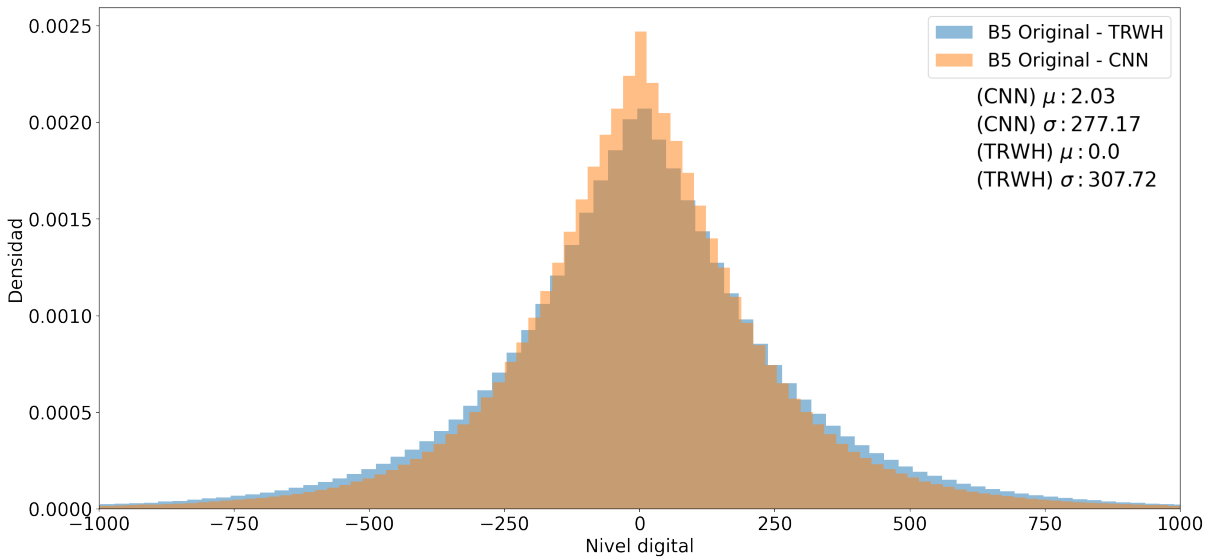



Figura 6.9: Banda 5 del satélite Landsat 8 frente a las imágenes fusionadas mediante los distintos modelos utilizados. Arriba, de izq a dch: original, Brovey, HPF. Abajo, de izq a dch: IHS, wavelet (TRWH) y CNN. También se presentan los histogramas producidos al restar la banda original de la banda CNN, y la banda original de la banda TRWH.

Al igual que pasaba en las bandas fusionadas del satélite Sentinel-2, los métodos Brovey y HPF, son los que menos respetan la coherencia espectral de la banda original y, por lo tanto, los que más han cambiado el aspecto original de las bandas MS durante la fusión. Estas bandas presentan un aspecto más oscurecido que las originales, lo cual suele estar asociado a una pérdida o disminución del contraste durante el proceso. Podemos determinar que el método con más dificultades para mantener el tono de la imagen es Brovey, ya que se aprecian grandes distorsiones en las distintas bandas.

Al igual que ocurría con el satélite Sentinel-2, los mejores resultados espectrales los producen los métodos: Transformada Wavelet aditivo IHS y CNN. Estos resultados se pueden calificar como muy buenos, ya que no se aprecia diferencia en ninguna de las bandas estudiadas. Los histogramas confirman los buenos resultados obtenidos por el método CNN, manteniendo la distribución de la diferencia entre bandas centrada en cero y con una desviación estándar inferior a 350 niveles digitales para todas las bandas.

Si nos fijamos ahora en la calidad espacial de las bandas fusionadas, los siguientes mosaicos muestran una pequeña parte destacada de la imagen, con lo que se pretende evaluar la nitidez de los detalles y bordes.




Figura 6.10: Área destacada de las bandas 2 y 3 (de 30 m de resolución) frente a las imágenes obtenidas mediante los distintos métodos de fusión (15 m de resolución). Arriba, de izq a dch: banda original, fusión Brovey, HPF. Abajo, de izq a dch: IHS, Wavelet y CNN.




Figura 6.11: Área destacada de las bandas 4 y 5 (de 30 m de resolución) frente a las imágenes obtenidas mediante los distintos métodos de fusión (15 m de resolución). Arriba, de izq a dch: banda original, fusión Brovey, HPF. Abajo, de izq a dch: IHS, Wavelet y CNN.

En lo referente a la calidad espacial, todos los métodos proporcionan resultados satisfactorios, ya que todas las imágenes han mejorado su calidad espacial con respecto a la banda original.

– Evaluación Cuantitativa

Al igual que en el caso del satélite Sentinel-2 (apartado [4.1.2](#)), para poder realizar este análisis y poder comparar las imágenes originales con las obtenidas de los proceso de fusión, se han degradado las bandas espectrales originales de modo que la banda pancromática de 15 m se ha pasado a 30 m y las bandas de 30 m han pasado a 60 m. De este modo, después de aplicar los métodos de fusión, las bandas obtenidas tendrán la misma resolución que las originales, y se pueden comparar directamente. La degradación de las imágenes se realizó aplicando un filtro binomial.

Además, para probar que los resultados obtenidos se pueden extrapolar a cualquier otra imagen, este estudio se ha realizado para cinco imágenes diferentes, de cinco países diferentes. Los resultados presentados en las distintas tablas representan la media de los datos obtenidos para cada una de las cinco imágenes.

– Ergas espectral

Banda	IHS	Brovey	HPF	IHS TRWH	CNN
B1	2.704	15.633	6.235	1.504	0.940
B2	2.834	16.271	6.383	1.544	1.029
B3	3.011	16.578	6.483	1.680	1.213
B4	2.426	16.832	6.588	1.627	1.456
B5	3.777	14.194	6.434	1.700	1.584
B6	4.403	12.361	6.112	1.774	1.661
B7	4.247	12.569	6.002	1.904	1.746

Tabla 6.3: Valores obtenidos para el coeficiente Ergas espectral según los distintos métodos de fusión empleados para las imágenes del satélite Landsat 8.

Los resultados obtenidos mediante el coeficiente ERGAS espectral reflejan mejor lo observado en los mosaicos e histogramas del análisis cualitativo, y muestran que el método de Brovey no proporciona buenos resultados espectrales. Tampoco se pueden considerar buenos los resultados obtenidos con el método HPF.

Los resultados de los métodos de transformada de wavelet y CNN son, sin embargo, muy buenos, manteniendo los valores por debajo de 2 en todas las bandas. El método que mejores resultados ofrece es el método de fusión mediante redes neuronales.

– Ergas espacial

Banda	IHS	Brovey	HPF	IHS TRWH	CNN
B1	0.876	6.563	5.886	2.628	2.922
B2	0.588	6.501	5.875	2.363	2.697
B3	1.491	5.451	5.684	1.550	2.270
B4	2.470	4.941	6.012	1.920	2.670
B5	6.366	6.900	10.603	8.762	9.180
B6	8.416	9.450	12.921	11.309	11.770
B7	7.771	8.729	11.644	9.882	10.405

Tabla 6.4: Valores obtenidos para el coeficiente Ergas espacial en los distintos métodos de fusión empleados para las imágenes del satélite Landsat 8.

Los mejores resultados los obtienen son el método IHS, el modelo de transformada de wavelet aditivo por IHS, y el algoritmo CNN, con resultados buenos en las bandas 1-4. Los valores obtenidos en todos los métodos para las bandas 6 y 7 son claramente más elevados que los del resto de las bandas.

Índice de figuras

1.1. Componentes de un sistema de teledetección	4
1.2. Esquema del espectro electromagnético	5
1.3. Esquema del proceso que sufre la Energía electromagnética en la superficie de la Tierra	7
1.4. Firmas espectrales de cinco cubiertas habituales en teledetección	8
1.5. Espectro de radiación solar	11
1.6. Imagen multiespectral	14
1.7. Relación IFOV-tamaño de píxel	15
1.8. Resolución espectral de los satélites Sentinel-2, Landsat 7 y Landsat 8	17
1.9. Imagen con líneas de píxeles perdidos.	21
1.10. Imagen multiespectral con errores de bandeado.	22
1.11. Sensor OLI, Landsat 8.	31
1.12. Sensor TIRS, Landsat 8.	32
1.13. Sensor MSI, Sentinel-2.	37
2.1. Embalse de Cedillo, 11 de abril 2019	42
2.2. Espectros de reflectividad del agua “clara” y del agua turbia	46
2.3. Esquema de los procesos de absorción y dispersión de la radiación en el agua	49
2.4. Espectro de absorción de una muestra de agua con una concentración de 25 mg/l del alga verde <i>Chlorella vulgaris</i>	51

2.5. Disco Secchi	54
3.1. Embalse del Val, imagen obtenida con el satélite Sentinel-2 el 15/03/2018	58
3.2. Localización geográfica de la sonda “Aquadam”	59
3.3. Distribución de los diferentes puntos de muestreo localizados en el embalse de El Val	62
3.4. Esquema de medición por espectrofotometría	64
3.5. Esquema del funcionamiento de un espectrofotómetro	65
3.6. Esquema espectrofotómetro de doble haz	65
3.7. Espectro de absorción de una solución de clorofila disuelta en agua a una concentración de 500 $\mu\text{gr/l}$	72
3.8. Bandas espectrales de los satélites Sentinel-2 y Landsat 8 sobre el espectro de absorción de una dilución a alta concentración de clorofila	74
3.9. Espectros de absorción obtenidos para diluciones con diferentes concentra- ciones de clorofila	76
3.10. Proceso seguido para aislar las diferentes bandas de absorción de la clorofila	79
3.11. Concentración de clorofila de las muestras estudiadas, frente a el área de las bandas de absorción a diferentes concentraciones.	81
4.1. Diagrama del proceso de fusión entre las bandas MS y PAN	86
4.2. Arquitectura y pseudocódigo del algoritmo de fusión por redes neuronales convolucionales	91
4.3. Imágenes del satélite Sentinel-2 utilizadas en la fusión	97
4.4. Banda 5 original del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos algoritmos utilizados	101
4.5. Banda 6 original del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos algoritmos utilizados	103

4.6. Banda 7 original del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos algoritmos utilizados	105
4.7. Banda 8 original del satélites Sentinel-2, frente a las imágenes fusionadas mediante los distintos algoritmos utilizados	107
4.8. Área destacada de las bandas 5 y 6 originales frente a las imágenes obtenidas mediante los distintos métodos de fusión	109
4.9. Área destacada de las bandas 7 y 8A originales frente a las imágenes obtenidas mediante los distintos métodos de fusión	110
4.10. Esquema del efecto de la atmósfera en la radiación solar	116
4.11. Radiómetros hiper-espectrales colocados en Doñana para realizar la calibración de los datos de teledetección	119
5.1. Mapa de la península ibérica y posicionamiento geográfico del embalse de “El Val”.	126
5.2. Diagrama de flujo de los distintos niveles de procesamiento aplicados a los datos satelitales. Adaptada de [101].	130
5.3. Evolución de la temperatura superficial del embalse de “El Val” entre los años 2018-2022	134
5.4. Temperatura medida in-situ en la superficie del embalse de “El Val”, frente a las estimadas para las bandas B10 y B11 del satélite Landsat 8.	141
5.5. Relación entre la temperatura medida in-situ y la temperatura estimada mediante teledetección en la superficie del embalse de “El Val”	143
5.6. Histogramas que muestran el error cometido al estimar la temperatura mediante las bandas térmicas 10 y 11	143
5.7. Modelos de regresión ajustados para estimar la temperatura superficial mediante las radiancias de las bandas térmicas B10 y B11	144
5.8. Histogramas que reflejan el error cometido al estimar la temperatura mediante el modelo de regresión múltiple	146

5.9. Evolución temporal de la temperatura medida in-situ frente a la temperatura estimada por regresión lineal	148
5.10. Comparación entre la temperatura medida in-situ y la temperatura estimada mediante un modelo de regresión calibrado únicamente con los datos de 2018	150
5.11. Distribución que refleja la diferencia entre la temperatura medida in-situ y la estimada por regresión mediante un modelo calibrado únicamente con los datos de 2018	151
5.12. Evolución temporal de la temperatura medida in-situ y de la temperatura estimada mediante un modelo de regresión calibrado únicamente con los datos de 2018	153
5.13. Mapa de la temperatura superficial estimada mediante teledetección en el embalse de “El Val” el 13/07/2020	155
5.14. Comparación entre la temperatura medida in-situ en la segunda campaña de medición y la temperatura estimada mediante teledetección para los diferentes puntos de muestreo	155
5.15. Mapa de la temperatura superficial estimada mediante teledetección en el embalse de “El Val” el 15/09/2020	158
5.16. Comparación entre la temperatura medida in-situ en la segunda campaña de medición y la temperatura estimada mediante teledetección para los diferentes puntos de muestreo	159
5.17. Evolución temporal de la turbidez media en la capa fótica del embalse de “El Val” en los años 2018-2022	162
5.18. Evolución temporal de la turbidez media en la capa fótica del embalse de “El Val” en los años 2018-2022 una vez eliminados los valores atípicos	164
5.19. Concentración media de clorofila-a medida en la capa fótica del embalse de “El Val” entre los años 2018-2022	168
5.20. Evolución anual de la concentración de clorofila-a detallada por meses.	169

5.21. Evolución de la función de pérdida obtenida en función de la arquitectura de la red	175
5.22. Espectros de reflectancia ρ_{TOA} , ρ_w y R_{rs} , tomados por el satélite Sentinel-2 en el embalse de “El Val” el 15/10/2021	178
5.23. Relación entre la concentración media de clorofila-a medida in-situ y estimada mediante teledetección, entre los años 2018-2022	181
5.24. Histogramas que muestran la distribución del error cometido al estimar la concentración de clorofila-a mediante teledetección	182
5.25. Evolución temporal de la clorofila-a medida por la sonda “Aquadam” en la capa fótica del embalse de “El Val” entre los años 2018-2022 frente a la clorofila-a estimada mediante teledetección	185
5.26. Relación entre la concentración de clorofila-a medida in-situ y estimada mediante teledetección, cuando la red neuronal ha sido entrenada con los datos de los dos primeros años	186
5.27. Evolución temporal de la clorofila-a medida por la sonda “Aquadam” frente a la clorofila-a estimada mediante teledetección, cuando la red neuronal ha sido entrenada con los datos de los dos primeros años	187
5.28. Mapa de la concentración de clorofila-a estimada mediante teledetección, en el embalse de “El Val” el día 17/07/2020	189
5.29. Comparación de las medidas tomadas in-situ y estimada mediante teledetección en los diferentes puntos de muestreo distribuidos por el embalse de “El Val”	190
5.30. Evolución temporal de la concentración de clorofila-a medida in-situ y estimada mediante teledetección entre los meses de julio y agosto de 2020	193
5.31. Evolución temporal y espacial estimada mediante teledetección del pico de concentración clorofila-a registrado entre julio y agosto de 2020	194
6.1. Diagrama del algoritmo de fusión IHS	222
6.2. Representación gráfica del algoritmo de Mallat	227


6.3. Esquema de la fusión sustitutiva usando el algoritmo de Mallat	228
6.4. Esquema del método Wavelet aditivo intensidad-matiz-saturación usando el algoritmo de Mallat	229
6.5. Imágenes del satélite Landsat 8 utilizadas en la fusión	233
6.6. Banda 2 original del satélite Landsat 8 frente a las imágenes fusionadas . .	236
6.7. Banda 3 original del satélite Landsat 8 frente a las imágenes fusionadas . .	238
6.8. Banda 4 original del satélite Landsat 8 frente a las imágenes fusionadas . .	240
6.9. Banda 5 original del satélite Landsat 8 frente a las imágenes fusionadas . .	242
6.10. Área destacada de las Bandas 2 y 3 originales frente a las imágenes fusionadas	244
6.11. Área destacada de las Bandas 4 y 5 originales frente a las imágenes fusionadas	245

Índice de tablas

1.1. Distribución espectral de los sensores OLI y TIRS del satélite Landsat 8	33
1.2. Especificaciones de productos LDCM a Nivel-1.	34
1.3. Distribución espectral del sensor MSI del satélite Sentinel-2	36
2.1. Valores límites de la OCDE para un sistema completo de clasificación trófica	43
2.2. Usos del agua en función del estado trófico	44
3.1. Perfil métrico vertical realizado por la sonda “Aquadam”, 30/09/2021 a las 14:00:00	61
3.2. Localización geográfica de los puntos de muestreo distribuidos en el embalse de “El Val”	63
3.3. Medidas físico-químicas realizadas en una muestra de agua con la sonda multiparamétrica “Hydrolab”	70
3.4. Diluciones preparadas a diferentes concentraciones de clorofila	71
3.5. Análisis de las bandas de absorción de 447, 498 y 687 nm a diferentes concentraciones de clorofila	80
4.1. Análisis de la calidad espectral mediante el índice ERGAS espectral para el satélite Sentinel-2	112
4.2. Análisis de la calidad espacial mediante el índice ERGAS espacial para el satélite Sentinel-2	113

5.1. Ejemplo de los datos tomados durante el perfil métrico vertical realizado por la sonda “Aquadam” el día 30/09/2021	128
5.2. Distribución temporal de las imágenes de los satélites Landsat 8 y Sentinel-2 utilizadas	129
5.3. Temperaturas máxima, mínima y media registradas en la superficie del embalse de “El Val” entre 2018-2022	135
5.4. Temperatura medida por la sonda “Aquadam” a 1m de profundidad los días 28 y 29 de septiembre de 2020	136
5.5. Distribución espectral de las bandas térmicas del sensor TIRS de Landsat 8	137
5.6. Constantes para calcular la temperatura de brillo a partir de los datos del sensor TIR	138
5.7. Análisis de los diferentes modelos propuestos para estimar la temperatura superficial	145
5.8. Temperatura medida in-situ (15/07/2020) y estimada (13/07/2020) mediante teledetección en los diferentes puntos de muestreo	155
5.9. Temperatura medida por la sonda “Aquadam” entre los días 16-22 de septiembre de 2020	157
5.10. Diferencia entre la temperatura medida y la estimada mediante teledetección en varios puntos del embalse el día 22/09/2020.	158
5.11. Turbidez medida por la sonda “Aquadam” en los perfiles de los días 7 y 8 de octubre de 2020	166
5.12. Evolución anual de la concentración de clorofila-a en la capa fótica del embalse de “El Val”, detallada por meses	170
5.13. Concentración de clorofila-a máxima, mínima y media registradas en el embalse de El Val entre los años 2018-2022	171
5.14. Concentración de clorofila-a medida por la sonda “Aquadam” en los perfiles de los días 26 y 27 de julio de 2020	172

5.15. Comparación de los resultados obtenidos en este estudio frente a otros encontrados en otro estudio de la bibliografía	183
5.16. Concentración de clorofila-a medida in-situ (15/07/2020) y estimada mediante teledetección (17/07/2020) en puntos de muestreo distribuidos a lo largo del embalse	190
6.1. Tamaño y valor central de la matriz de filtro en función de R	224
6.2. Valores correspondientes al parámetro M en función del valor del ratio R	225
6.3. Análisis de la calidad espectral mediante el índice Ergas espectral para el satélite Landsat 8	246
6.4. Análisis de la calidad espacial mediante el índice Ergas espacial para el satélite Landsat 8	247



Esta tesis aborda el problema de la monitorización de la calidad de las masas de agua continentales y los episodios de eutrofización a los que éstas pueden verse sometidas mediante los datos de teledetección espacial publicados en abierto por la Agencia Espacial Europea (European Space Agency, ESA) y la NASA (National Aeronautics and Space Administration) para sus misiones espaciales Sentinel-2 y Landsat 8 respectivamente. En este trabajo se introducen recientes técnicas de aprendizaje automático, como son los algoritmos de deep learning, tanto en el preprocesado de las imágenes como en la inferencia de las variables de calidad de agua a monitorizar. Gracias a estas técnicas se propone con éxito un nuevo método para monitorizar la temperatura y la concentración de clorofila de un embalse eutrofizado, estimando ambas variables de forma fiable tanto temporal como espacialmente. El resultado final es un sistema automático de monitorización del estado trófico de las masas de agua dulce a través de la concentración de clorofila-a, el cual utiliza únicamente los datos en abierto proporcionados por los principales satélites operativos.

This thesis addresses the problem of monitoring the quality of continental water masses and the eutrophication episodes through space remote sensing data published openly by the European Space Agency (ESA) and NASA (National Aeronautics and Space Administration) for their Sentinel-2 and Landsat 8 space missions. In this work, recent automatic deep learning techniques are introduced, both in the preprocessing of the images and the inference of the water quality variables to be monitored. Thanks to these techniques, a new method is successfully proposed to monitor the temperature and chlorophyll concentration of a eutrophic reservoir, estimating both variables reliably both temporally and spatially. The final result is an automatic system for monitoring the trophic state of freshwater masses through the concentration of chlorophyll-a, which only uses open data provided by the main operational satellites.