



UNIVERSIDAD DE CONCEPCIÓN
Dirección De Postgrado
Facultad De Ciencias Forestales
Programa de Magister en Ciencias Forestales

**VARIABILIDAD ESPACIOTEMPORAL DE PARÁMETROS BIOFÍSICOS
DE CALIDAD DEL AGUA INTEGRANDO DATOS IN-SITU Y
TELEDETECCIÓN: CASO LAGUNA GRANDE SAN PEDRO DE LA PAZ**

Tesis para optar al grado de Magister en Ciencias Forestales

Daniel Alonso Torres Poblete
CONCEPCIÓN - CHILE
2023

Profesor Guía: Dr. Santiago Yépez
Depto. de Manejo de Bosques y Medio Ambiente,
Facultad de Ciencias Forestales Universidad de Concepción

VARIABILIDAD ESPACIOTEMPORAL DE PARÁMETROS BIOFÍSICOS DE CALIDAD DEL AGUA INTEGRANDO DATOS IN-SITU Y TELEDETECCIÓN: CASO LAGUNA GRANDE SAN PEDRO DE LA PAZ

Comisión Evaluadora:

Santiago Yépez Figueroa (Profesor guía)
Dr. en Hidrosedimentología y Sensores
Remotos

German Velásquez Acosta (Profesor co-guía)
Dr. en Metalogénesis

Cesar Rubén Fernández de Villarán
(Profesor co-guía)
Dr. en Ingeniería de Montes

Rolando Rodríguez Leiva
(Comisión evaluación)
Dr. en Ciencias Forestales

Luc Bourrel (Comisión evaluación)
Dr. en Hidroclimatología

Lien Rodríguez López (Comisión evaluación)
MSc. Bioinformática y Biología Computacional

Director de Postgrado:
Dr. Regis Texeira
Ingeniero Químico, PhD

DEDICATORIA

“A Gloria Poblete Montero, Pablo Torres Leyton y Pablo Torres Poblete”

AGRADECIMIENTOS

Agradezco a mi familia y mis amigos, mis pilares fundamentales en esta vida, por el amor y el apoyo constante que me brindaron durante todo este proceso. A mi profesor guía Santiago Yépez por confiar en mí, por su paciencia para enseñarme cosas desde cero y su apoyo constante durante todos estos años.

Al profesor César Rubén Fernández De Villarán de la Universidad de Huelva por su apoyo durante mi estancia en España y a la AUIP el haber facilitado esta experiencia de movilidad.

Al apoyo de la ANID a través del proyecto Fondecyt Regular (1221091) “Seasonal and interannual variability of Inherent and Apparent Optical Properties in lakes and reservoirs in south-central Chile: Implications for bio-optical modeling and water quality”. También agradecer el apoyo brindado por el personal del centro EULA de la Universidad de Concepción en la toma de datos en el lago y análisis de laboratorio. Asimismo, a la Gerencia de Planificación y Mejora Continua de la forestal ARAUCO S.A. por el apoyo en la colecta de datos de espectrometría en terreno en la Laguna Grande.

TABLA DE CONTENIDOS

ÍNDICE DE TABLAS.....	7
ÍNDICE DE FIGURAS	8
RESUMEN	10
ABSTRACT	11
1. INTRODUCCIÓN.....	12
2. HIPÓTESIS	17
3. OBJETIVOS	17
3.1. Objetivo general	17
3.2. Objetivos específicos.....	17
4. MATERIALES Y METODOS	18
4.1. Área de estudio	18
4.2. Datos de campo de los parámetros del agua	20
4.3. Medición sobre el terreno de las firmas espectrales del agua (Rrs)	22
4.4. Datos de imágenes satelitales y métodos de corrección atmosférica.....	24
4.4.1. Imágenes del satélite Landsat-8 OLI	24
4.4.2. Métodos de corrección atmosférica	26
4.5. Metodología de modelización de la calidad del agua	29
4.6. Selección de índices espectrales.....	30
4.7. Evaluación estadística	32
5. RESULTADOS	33
5.1. Mediciones sobre el terreno de los parámetros del agua	33
5.2. Corrección atmosférica.....	34
5.2.1. Evaluación de los niveles de aerosoles en los puntos de las estaciones de muestreo	34
5.2.2. Evaluación de los métodos de corrección atmosférica	36
5.3. Modelos empíricos de estimación de Chl-a y turbidez.....	39
5.3.1. Análisis de estimación de Chl-a.....	39
5.3.2. Análisis de estimación de la turbidez.....	42
5.5. Evaluación estadística y solidez del modelo.....	43
5.5.1. Evaluación estadística y robustez del modelo de estimación de Chl-a	43

5.5.2. Evaluación estadística y solidez del modelo de estimación de la turbidez...	47
5.6. Variabilidad espacial y temporal	51
6. DISCUSIÓN Y CONCLUSIONES.....	55
7. ANEXOS	59
8. BIBLIOGRAFÍA	62

ÍNDICE DE TABLAS

Tabla 1. Concentraciones de Chl-a y turbidez obtenidas de las muestras de agua de Laguna Grande.	21
Tabla 2. Valores de temperatura, oxígeno disuelto, saturación de oxígeno, conductividad y pH obtenidos en la Laguna Grande.....	22
Tabla 3. Bandas espectrales del sensor L-8 OLI y sus principales características de resolución espacial.	24
Tabla 4. Las tres imágenes del satélite L-8 OLI utilizadas para desarrollar los modelos de estimación espectral de Chl-a y turbidez.	26
Tabla 5. Imágenes del satélite L-8 OLI utilizadas para estudiar la variabilidad espaciotemporal de los parámetros bioópticos en el lago durante diferentes condiciones estacionales entre ciclos hidrológicos para 2014 y 2022.	27
Tabla 6. Principales combinaciones de bandas e índices utilizados para estimar Chl-a y Turbidez en la Laguna Grande.	33
Tabla 7. Adaptación de la tabla de valores SR_QA_AEROSOL de Landsat 8-9.	37
Tabla 8. Modelos de estimación de la Chl-a y de turbidez para cada método de corrección atmosférica analizado.	39

ÍNDICE DE FIGURAS

Figura 1. Localización de la "Laguna Grande San Pedro de la Paz", mostrando la distribución de las 40 estaciones de muestreo superficial.....	19
Figura 2. Equipo utilizado en campo para la toma de muestras de agua.....	21
Figura 3. Espectros R_{rs} medidos in-situ con su correspondiente valor de Chl-a.....	23
Figura 4. Flujo de trabajo para el análisis de datos de imágenes in-situ y por satélite.....	30
Figura 5. Las estaciones de muestreo de Chl-a y turbidez se localizan sistemáticamente cubriendo un buffer de 60, 40 y 20 m sobre la imagen de calidad del modelo LaSRC, que representa los niveles de aerosol en la escena.....	35
Figura 6. Comparación de los resultados de la corrección atmosférica y los datos del radiómetro de campo para la Laguna Grande. La línea negra representa la reflectancia real en la superficie del agua utilizada en el análisis comparativo como referencia.....	38
Figura 7. Correlación entre la reflectancia de la superficie del agua (perfiles espectrales) y la concentración de Chl-a obtenida durante el estudio de campo del 6 de enero de 2023.....	40
Figura 8. Relación entre la concentración de Chl-a y la reflectancia a las longitudes de onda de 655 nm y 880 nm.....	40
Figura 9. Mapa de calor utilizado para evaluar diferentes índices espectrales (GCI, NDVI y GNDVI) con datos de Chl-a in-situ ($\text{mg}\cdot\text{m}^{-3}$), utilizando valores de reflectancia de ACOLITE.....	41
Figura 10. Mapa de calor utilizado para evaluar diferentes combinaciones de bandas (Rojo, NDTI, Rojo+NIR, Azul/Verde, NIR, NIR/Rojo y NDTI) con datos de turbidez in-situ (NTU) utilizando reflectancia ACOLITE.....	43
Figura 11. Curva de calibración entre los datos de Chl-a in-situ y el índice GCI con la aplicación de la técnica bootstrapping, utilizando el ajuste medio en los parámetros con 1000 iteraciones, tomando el 80% del conjunto de datos en cada iteración para calcular la correlación y el 20% restante para la validación.....	44
Figura 12. Comparación de Chl-a medido frente a Chl-a estimado a partir de imágenes Landsat-8 OLI utilizando el algoritmo GCI (ecuación 8) con datos ACOLITE (reflectancia corregida).....	45

Figura 13. Valores residuales de Chl-a frente a valores predichos de Chl-a ($\text{mg}\cdot\text{m}^{-3}$), mostrando una baja dispersión en los valores en todo el rango de Chl-a, de 3 a $8 \text{ mg}\cdot\text{m}^{-3}$.	46
Figura 14. Distribución de la media del parámetro “a” (controla la amplitud que puede alcanzar la función exponencial) y del parámetro “b” (controla la tasa de crecimiento) para el caso de Chl-a utilizando el índice espectral GCI, con el procesador Acolite.	47
Figura 15. Curva de calibración entre los datos de turbidez in-situ (NTU) y el índice Red+NIR con la aplicación de la técnica bootstrapping utilizando el ajuste medio en los parámetros con 1000 iteraciones, utilizando el 80% del conjunto de datos en cada iteración para calcular la correlación y el 20% restante para la validación.	48
Figura 16. Comparación de la turbidez medida frente a la turbidez estimada a partir de imágenes Landsat-8 OLI utilizando el algoritmo Red+NIR (ecuación 9) con datos ACOLITE (reflectancia corregida).	49
Figura 17. Los residuos de las observaciones de turbidez in-situ comparados con los valores de turbidez previstos (NTU). Obsérvese que los datos no se dispersan uniformemente en torno a cero, y que todos los errores residuales se sitúan aproximadamente en el intervalo de -3,5 a 3,5 NTU.	50
Figura 18. Distribución de la media del parámetro “a” (controla la amplitud que puede alcanzar la función exponencial) y del parámetro “b” (controla la tasa de crecimiento) para el caso de turbidez utilizando la combinación de bandas Red + NIR, con el procesador Acolite.	51
Figura 19. Mapas de distribución de Chl-a para el Lago Laguna Grande mostrando los cambios de concentración a lo largo de las estaciones de Invierno, Primavera, Verano y Otoño en 2022 (a-d) y 2014 (e-h), permitiéndonos evaluar las fluctuaciones estacionales.	52
Figura 20. Diagrama de araña que ilustra la variabilidad de Chl-a a lo largo de las estaciones en las zonas norte (a) y sur (b). Se representan los valores medios de 2022 (línea azul) y 2014 (línea roja), resaltando la región de interés dentro de cada sección lacustre.	53

RESUMEN

Este estudio tiene como objetivo desarrollar e implementar una metodología para la estimación de parámetros bio-ópticos en una laguna ubicada en la región del Biobío, en el centro-sur de Chile, mediante el análisis de series temporales de imágenes satelitales Landsat-8, específicamente utilizando el sensor multiespectral OLI. Los parámetros bio-ópticos, es decir, la clorofila-a ($\text{mg}\cdot\text{m}^{-3}$) y la turbidez (NTU) también se midieron in-situ sincronizados con los pases del satélite para minimizar el impacto de las distorsiones atmosféricas. Para calibrar las imágenes de satélite, se evaluaron varios métodos de corrección atmosférica (incluidos ACOLITE, C2RCC, iCOR y LaSRC) durante la fase de preprocesamiento de las escenas. A continuación, se compararon las firmas espectrales obtenidas de las escenas para cada modelo de corrección atmosférica con las firmas espectrales adquiridas in-situ en la superficie del agua. En resumen, el modelo ACOLITE resultó ser el que mejor se ajustaba al proceso de calibración. Posteriormente, aprovechamos los datos de reflectancia derivados del modelo ACOLITE para establecer correlaciones entre diversos índices espectrales y datos in-situ. Los modelos empíricos de recuperación (basados en combinaciones de bandas) que mostraron un rendimiento superior, como indican los valores R^2 más altos, fueron sometidos a una rigurosa validación estadística y optimización mediante la aplicación de un enfoque de bootstrapping. Nuestro análisis abarcó un espectro de fechas, estaciones y años, lo que nos permitió profundizar en la evolución del estado trófico asociado al lago. Identificamos un llamativo periodo de ocho años (2014-2022) caracterizado por un descenso de la concentración de clorofila-a en el lago, posiblemente atribuible a las medidas gubernamentales adoptadas en la región para la protección y conservación del lago. Los resultados de este estudio inicial sirven de base para la creación de un sistema de seguimiento moderno que mejora los métodos tradicionales basados en mediciones puntuales, ofreciendo una visión holística de los procesos en curso dentro del lago.

ABSTRACT

This study aims to develop and implement a methodology for retrieving bio-optical parameters in a lagoon located in the Biobío region, in south-central Chile by analyzing time series of Landsat-8 satellite images, specifically using the multispectral OLI sensor. The bio-optical parameters, i.e., chlorophyll-a ($\text{mg}\cdot\text{m}^{-3}$) and turbidity (NTU) were also measured in-situ synchronizes with the satellite passes to minimize the impact of atmospheric distortions. To calibrate the satellite images, various atmospheric correction methods (including ACOLITE, C2RCC, iCOR, and LaSRC) were evaluated during the image preprocessing phase. Spectral signatures obtained from the scenes for each atmospheric correction model were then compared with spectral signatures acquired in-situ on the water surface. In short, the ACOLITE model emerged as the best fit for the calibration process. Subsequently, we harnessed the reflectance data derived from the ACOLITE model to establish correlations between various spectral indices and the in-situ data. The empirical retrieval models (based on band combinations) that showed superior performance, as indicated by higher R^2 values, were subjected to rigorous statistical validation and optimization by applying a bootstrapping approach. Our analysis covered a spectrum of dates, seasons, and years, which allowed us to delve deeper into the evolution of the trophic state associated with the lake. We identified a striking eight-year period (2014-2022) characterized by a decline in chlorophyll-a concentration in the lake possibly attributable to governmental measures in the region for the protection and conservation of the lake. The results of this initial study serve as the basis for the creation of a modern monitoring system that enhances traditional point-based methods, offering a holistic view of the ongoing processes within the lake.

1. INTRODUCCIÓN

Los lagos de las zonas urbanas contribuyen a la calidad de vida proporcionando servicios ecosistémicos ecológicos y sociales, definidos como los beneficios que las personas reciben del medio ambiente. Estos lagos representan sistemas intrincados que garantizan la prestación continuada de una serie de servicios ecosistémicos, especialmente en entornos lacustres urbanos, lo que exige actuaciones integradas coherentes en la cuenca hidrográfica circundante o directamente en el propio lago (Millenium Ecosystem Assessment, 2005; Cooke et al., 2016). Garantizar la calidad de las aguas superficiales y subterráneas es un deber esencial de las organizaciones responsables del suministro y la gestión del agua (Abdelal et al., 2022). Es crucial aplicar medidas adecuadas de conservación y gestión para proteger y mejorar la calidad del agua en los cuerpos de agua, salvaguardando así su valor ecológico y socioeconómico a largo plazo (van Rees et al., 2021) mediante el análisis del estado trófico de un lago. El estado trófico de un lago indica su nivel de productividad biológica y la calidad del agua, viene determinada por la disponibilidad de nutrientes. La medición numérica de la salud trófica y el nivel de contaminación de los cuerpos de agua es de suma importancia en la gestión ambiental de una región, ya que ayuda a establecer limitaciones en la utilización de estos recursos y, a dirigir esfuerzos de recuperación y reducción de impacto cuando sea necesario (Parra et al., 2003). Los lagos pueden clasificarse en diferentes estados tróficos, como oligotrófico (baja productividad), mesotrófico (productividad moderada) o eutrófico (alta productividad) (Carlson, 1977). Este estado influye significativamente en la diversidad y abundancia de especies acuáticas, así como en la presencia de algas y otros organismos.

Normalmente, para controlar la calidad del agua se utiliza un método tradicional basado en puntos que proporciona datos de alta calidad. Sin embargo, estos datos suelen representar puntos de muestreo aislados y no reflejan plenamente las amplias variaciones espaciales y temporales del ecosistema acuático (Lei et al., 2020). Para hacer frente a los retos relacionados con la cobertura espacial y temporal, la teledetección se ha reconocido como una solución óptima, aprovechando los avances en sensores y metodologías. Esto ha llevado a una

amplia utilización de la tecnología de satélites en el seguimiento de los cambios en las masas de agua dulce (Huang et al., 2023). El empleo de sistemas de teledetección por satélite permite observar y estudiar la calidad del agua a escala regional y mundial (Peterson et al., 2020). Así pues, la teledetección ofrece una perspectiva completa e inmediata de los sistemas acuáticos, atmosféricos y terrestres, así como importantes ventajas sobre los métodos tradicionales de seguimiento, como la cobertura a gran escala, la capacidad de seguimiento en tiempo real y la rentabilidad. Constituye una herramienta óptima para el seguimiento continuo de la calidad del agua en masas superficiales (Sòria-Perpinyà et al., 2020; Yépez et al., 2018; Rodríguez-López et al., 2020). Cuando se combina con mediciones in-situ, puede proporcionar evaluaciones del cambio sin precedentes, rentables y cuantitativas. Proporciona resoluciones espaciales que alcanzan la escala de metros y una frecuencia temporal que supera los intervalos diarios (Steissberg et al., 2010).

Es importante recalcar que, a pesar de los importantes avances en teledetección, todavía existe mucha incertidumbre en los algoritmos aplicados a los diferentes tipos ópticos de agua, ya que cada tipo de agua ofrece una respuesta diferente en función del algoritmo aplicado (Tavares et al., 2021). En este sentido, actualmente se están realizando estudios para mejorar y perfeccionar estos algoritmos de forma que sean cada vez más adaptables a cualquier tipo de condición. Según esto, un pilar fundamental para este tipo de análisis son la aplicación de métodos de corrección atmosférica, ya que los sensores pueden verse influenciados de forma importante por moléculas gaseosas y aerosoles presentes en la atmósfera, que pueden absorber y dispersar la luz reflejada desde la superficie, especialmente en las longitudes de onda más pequeñas, generando así distorsiones que influyen en la señal recibida por el sensor (Moses et al., 2017). Como se mencionó anteriormente, no todos los algoritmos responden de la misma manera, ya que su desempeño dependerá de las propiedades ópticas de la masa de agua analizada, por lo cual en esta investigación se evaluarán cuatro métodos de corrección atmosférica, ACOLITE, iCOR, Land Surface Reflectance Code (LaSRC) y Case 2 Regional Coast Colour (C2RCC).

Una de las fuentes más importantes de datos de teledetección es el archivo de la costelación Landsat. Siendo utilizado en este estudio el sensor OLI (Operational Land Imager) del satélite Landsat-8 (L-8) OLI dada su accesibilidad, frecuencia temporal adecuada, resolución espacial y los métodos de utilización del instrumento para determinar los datos de calidad del agua (Abbas et. al,2019; Normandin et. al, 2019). Además, este sensor tiene una alta resolución radiométrica, crucial para recuperar los constituyentes, ya que las masas de agua actúan como objetos oscuros y absorben una fracción mayor de la irradiancia descendente, lo que resulta en una baja relación señal-ruido (SNR) (Niroumand-Jadidi et. al, 2022). Las imágenes de satélite adquiridas por los satélites Landsat facilitan el seguimiento mensual de regiones específicas dentro de las masas de agua continentales. Estos conjuntos de datos proporcionan información crucial para los responsables políticos locales, los gestores del agua y del medio ambiente, así como para los investigadores (Zhang et al., 2022).

Al examinar la calidad del agua de los lagos mediante imágenes de satélite, la clorofila-a (Chl-a - en $\text{mg}\cdot\text{m}^{-3}$) y la turbidez (Unidades Nefelométricas de Turbidez - NTU) destacan como dos Parámetros Ópticos Aparentes (AOPs) esenciales para abordar este reto (Olmanson, 2015; Schaeffer, 2013). La clorofila se utiliza habitualmente para evaluar el estado trófico de las aguas costeras e interiores debido a su sensibilidad y rápida respuesta a diversos factores ambientales. La clorofila es el pigmento verde que se encuentra en las plantas acuáticas, como las algas y las cianobacterias (Li et al., 2023; Schaeffer, 2013). Un aumento de la concentración de Chl-a puede indicar la proliferación de estos organismos, a menudo asociada a la eutrofización, un fenómeno donde se produce el exceso de nutrientes en el agua (como el nitrógeno y el fósforo), lo cual favorece el crecimiento excesivo de algas (Ha et al., 2017), lo que puede tener efectos negativos sobre la calidad del agua y la salud del ecosistema acuático. La turbidez, que es una característica significativa que pertenece a las propiedades ópticas del agua y juega un papel crucial en la determinación de la calidad del agua. Los niveles elevados de turbidez (NTU) pueden dar lugar a un aspecto opaco, brumoso o turbio del agua, lo que está estrechamente relacionado con las concentraciones de sedimentos en suspensión (Garg et al.,

2017). En consecuencia, el seguimiento de la turbidez es vital para evaluar la calidad del agua e identificar los impactos antropogénicos derivados de actividades como el dragado, la erosión y la eutrofización (Sòria-Perpinyà et al., 2020).

La Laguna Grande se ubica en la comuna de San Pedro de la Paz en el Centro-Sur de Chile. Su cuenca ha sufrido importantes modificaciones debido a la introducción de plantaciones forestales (*Pinus radiata* y *Eucalyptus globulus*) y a la expansión urbana (Cruces et al., 2001). A lo largo del tiempo, multitud de factores externos y causas naturales han contribuido al deterioro de la calidad del agua de la laguna. Principalmente, este deterioro puede atribuirse a la aparición de procesos de eutrofización. La eutrofización es un fenómeno natural que suele desarrollarse a lo largo de miles de años; sin embargo, las actividades humanas pueden acelerar este proceso, dando lugar a la aparición de lo que comúnmente se denomina eutrofización artificial o cultural (Parra, 1989). Para examinar y analizar exhaustivamente el estado actual, hace algunas décadas la Dirección General de Aguas (DGA) estableció tres estaciones de muestreo dentro de la laguna, denominadas Sector Desagüe, Sector Centro y Sector Sur. Estas estaciones facilitaron la recolección de mediciones tradicionales, por ejemplo, Clorofila-a, Turbidez, pH, CDOM, para evaluar la calidad del agua de la laguna y su condición trófica. Estas tres estaciones de muestreo funcionaron desde 1988 hasta 2013, pero lamentablemente ya no están operativas. Desde 2014, el muestreo se realiza únicamente en la estación Sector Centro 2, pero la información disponible solo incluye tres misiones de muestreo por año entre 2014 y 2016. Asumiendo cuatro mediciones por año, el porcentaje de datos faltantes en las estaciones Centro, Desagüe, Sur y Centro 2 entre 1988 y 2016 es del 28% (Pedreros-Guarda et al., 2021). Estos factores sirven de punto focal para abordar el problema principal que este estudio pretende resolver.

La mayoría de los estudios realizados en la "Laguna Grande San Pedro de La Paz" mediante teledetección suelen hacerse a una escala temporal fija. Por ejemplo, Lillo-Saavedra et al. (2008) han demostrado la precisión de la estimación de características representativas de la calidad del agua en la laguna utilizando

imágenes de satélite fusionadas. Quintana-Sotomayor et al. (2012), publicaron un estudio implementando una metodología de clasificación orientada a objetos, para imágenes multiespectrales, para cuantificar los niveles de turbidez y generar un mapa de turbidez de la laguna. Rojas (2018), centró su estudio en evaluar los efectos de los cambios de uso del suelo en la cuenca de la Laguna Grande sobre las tasas de sedimentación. Esto se logró mediante un análisis multitemporal utilizando imágenes satelitales. Recientemente, Pedreros-Guarda et al. (2021), implementaron seis métodos automatizados para recuperar la temperatura superficial del agua de la laguna usando imágenes térmicas satelitales.

En el contexto nacional, la aplicación de sensores remotos para el estudio de la calidad del agua en ecosistemas lacustres es aún escasa. Por otra parte, la DGA desarrolló un exhaustivo diagnóstico de nuevas tecnologías para el monitoreo del estado trófico de los 20 lagos que forman parte de la Red Nacional de Control de Lagos Mínimos. Este informe destaca la aplicabilidad de sensores hiperespectrales y multiespectrales y la necesidad de aumentar la cobertura de monitoreo a nivel nacional, considerando la alta demanda y presión sobre los recursos hídricos (DGA, 2014).

Así, nuestro principal objetivo es desarrollar modelos de inversión espectral basados en datos in-situ versus la señal de reflectancia para estimar dos de los Parámetros de Calidad del Agua (WQPs) más importantes para la monitorización de la dinámica de la eutrofización, es decir, la concentración de Chl-a y la turbidez. Además, estos modelos desempeñarían un papel clave a la hora de rellenar las lagunas espaciales y temporales de los registros de datos históricos almacenados en la base de datos de la DGA. Los modelos empíricos de estimación facilitarían la reconstrucción del comportamiento de las variables durante periodos de tiempo específicos en los que no se recogieron datos de campo, aumentando así la robustez del conjunto de datos. Nuestro estudio abarcará los siguientes aspectos clave: i) *Aplicación de métodos de corrección atmosférica*: se emplearán diferentes métodos de corrección atmosférica para mitigar las distorsiones atmosféricas y el efecto de los reflejos solares en los datos de satélite adquiridos con el sensor Landsat-8 OLI; ii) *Desarrollo de un modelo*

empírico de estimación: Construiremos un modelo de inversión espectral adaptado para cuantificar con precisión los parámetros de calidad del agua, concretamente Chl-a y Turbidez, incluyendo una evaluación de la eficacia estadística; y iii) *Evaluación de la variabilidad espacio-temporal:* este análisis permitirá comprender los procesos de eutrofización durante diferentes condiciones estacionales y múltiples años.

2. HIPÓTESIS

El desarrollo metodológico y la sistematización de una herramienta, basada en datos in-situ y sensoramiento remoto, proveerá un sistema de detección más moderno y eficiente que el monitoreo tradicional puntual, permitiendo la evaluación de la Laguna Grande, en cuanto al riesgo potencial de desarrollar procesos de eutrofización.

3. OBJETIVOS

3.1. Objetivo general

Evaluar la variabilidad de parámetros biofísicos de calidad de agua en la Laguna Grande San Pedro de La Paz, basado en el uso combinado de datos in-situ y series temporales de imágenes satelitales.

3.2. Objetivos específicos

1. Emplear diferentes métodos de corrección atmosférica para abordar las distorsiones atmosféricas y los efectos de los reflejos solares (sun-glint) en los datos de satélite adquiridos con el sensor Landsat-8 OLI.
2. Desarrollar un modelo de inversión espectral para cuantificar con precisión los parámetros de calidad del agua, concretamente la clorofila-a y la turbidez.
3. Evaluar la variabilidad espacial y temporal de los parámetros de calidad de agua en la Laguna Grande entre 2014 y 2022.

4. MATERIALES Y METODOS

4.1. Área de estudio

La Laguna Grande de San Pedro de la Paz (Figura 1) es un lago urbano de poca profundidad ubicado en la parte noroeste de la cordillera de Nahuelbuta (36° 51' S, 73° 06' O) a 220 m.s.n.m., al sur del río Biobío, aproximadamente a 5 km de la ciudad de Concepción. Tiene un perímetro de 9800 metros, una longitud máxima de 2675 metros y un ancho máximo de 1.375 metros. En total, cubre un área de más de 155 hectáreas y alcanza una profundidad máxima de 13,5 metros, con una profundidad promedio de 8,1 metros (Cruces et al., 2001). En su lado oriental, la Laguna Grande está bordeada por una cadena montañosa de baja altitud que no supera los 360 m.s.n.m. Esta zona se caracteriza por plantaciones forestales, principalmente de pinos y eucaliptos (*Pinus radiata* y *Eucalyptus globulus*, respectivamente). Por otra parte, en las colinas situadas al norte, se ha desarrollado en los últimos años un importante proyecto urbanístico e inmobiliario, que se complementa con la construcción de la Villa San Pedro en la década de 2020, en el plano donde se encuentra. Destacan además los barrios de Andalué y El Venado, los cuales se encuentran en constante expansión. En esta área existen dos cuerpos de agua de gran importancia para la comunidad, la Laguna Grande y la Laguna Chica. Estos elementos son partes integrales de un sistema hidrológico más amplio que abarca humedales y estuarios. Los ecosistemas de lagos y humedales juegan un papel vital en el mantenimiento de una rica biodiversidad, que abarca una amplia variedad de especies como peces, reptiles, anfibios, aves y mamíferos (Pedreros-Guarda et al., 2021). La Laguna Grande drena a través del estero Los Batros, recibiendo agua de escorrentía natural, así como del drenaje de las zonas residenciales aledañas. La estabilidad de esta laguna es frágil y poco constante, dado que se trata de un cuerpo de agua cerrado y relativamente pequeño que se encuentra circundado por laderas de colinas propensas a la erosión y a la eutrofización debido al exceso de nutrientes que ingresan. A pesar de estas condiciones, es importante destacar que los niveles de contaminación se mantienen por debajo de los límites permitidos y, en consecuencia, no representan un peligro para la salud de la población (Rojas, 2018). La condición trófica actual (utilizando el Índice de Estado Trófico - TSI) de la Laguna

Grande de San Pedro fue categorizada como mesotrófica ($30 < \text{TSI} < 60$), basada en la clasificación del TSI de Carlson y los datos obtenidos por Urrutia et al. (2021).

En enero del año 2020, el sector de la laguna junto al humedal Los Batros fueron declarados santuario de la naturaleza, debido a que la laguna corresponde al cuerpo de agua más importante de San Pedro y de Concepción metropolitana, y posee características ecológicas particulares, dado que corresponde a una de las escasas zonas, a nivel comunal, con vegetación nativa, debido al desplazamiento de esta motivado por la urbanización y las plantaciones forestales; de igual modo, las formaciones vegetacionales presentes en los humedales se encuentran escasamente representadas dentro del Sistema Nacional de Áreas Silvestres Protegidas del Estado (SNASPE), tanto a nivel nacional como particularmente, dentro la Región del Biobío.

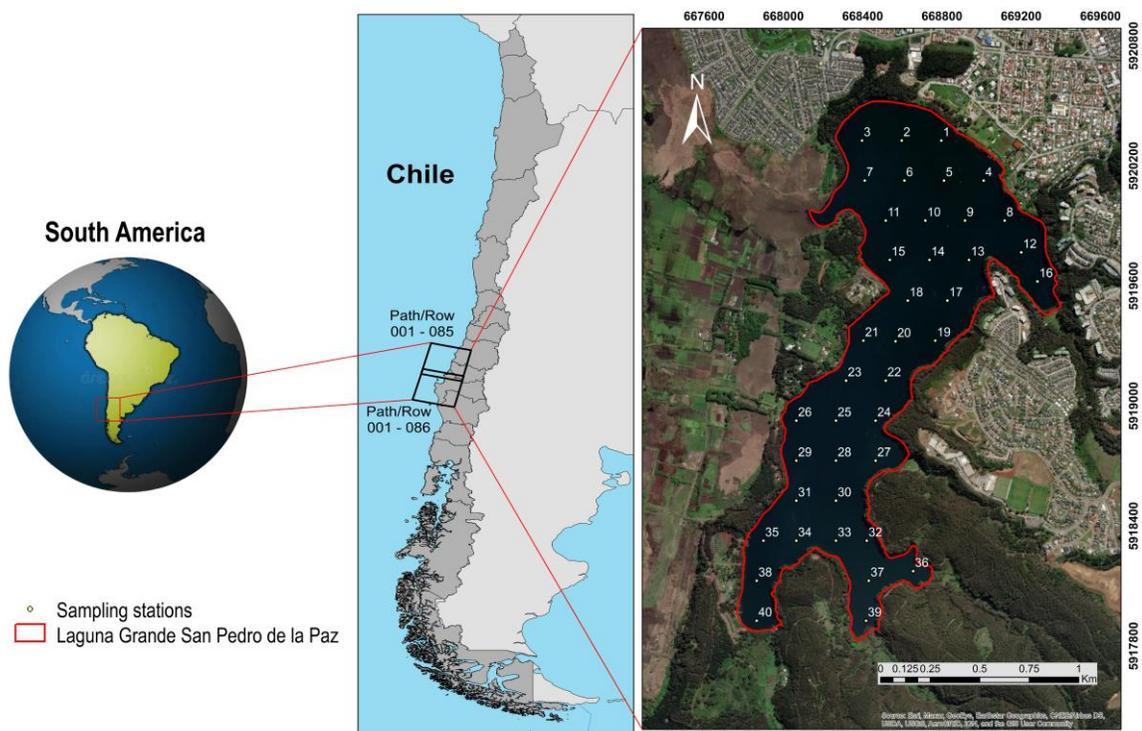


Figura 1. Localización de la "Laguna Grande San Pedro de la Paz", mostrando la distribución de las 40 estaciones de muestreo superficial.

4.2. Datos de campo de los parámetros del agua

Para este proyecto, se realizaron tres muestreos de campo para recoger muestras de agua superficial: i) el primero durante la estación primaveral (24 de octubre de 2022); ii) el segundo en la estación estival (6 de enero de 2023); y iii) el último cerca de la estación otoñal (1 de marzo de 2023). Las fechas seleccionadas se eligieron previamente en función del calendario actual de sobrevuelos del satélite L-8 sobre la laguna. Esta selección pretendía alinear nuestras salidas de campo con las fechas de adquisición de imágenes del satélite, minimizando el desfase temporal entre la captura de imágenes y la recogida de muestras.

Para determinar las ubicaciones de las estaciones de muestreo, se empleó una cuadrícula dentro del software ArcGIS 10.4.1. Se distribuyeron cuarenta (40) puntos de muestreo en el lago (Figura 1). Debido a limitaciones logísticas, se recogieron 40 muestras en la visita de verano, 25 en la de primavera y 20 en la de otoño, lo que supuso un total de 85 muestras. Estas muestras se recogieron utilizando botellas de vidrio de 1 litro, colocadas normalmente a unos 20-30 cm por debajo de la superficie del agua. Las muestras fueron analizadas en el laboratorio del Centro EULA-Chile y los resultados se resumen en la Tabla 1. Para el análisis de Chl-a, las muestras fueron sometidas a filtración, extracción y centrifugación, siguiendo el protocolo del método 445,0 de la EPA (Arar et al., 1997). Posteriormente, se utilizó fluorimetría para medir el contenido de clorofila-a, y se realizaron transformaciones y cálculos unitarios utilizando la curva de calibración correspondiente para el equipo Turner Designs modelo 10-AU-005-CE. Con este proceso se obtuvieron las concentraciones de clorofila-a en miligramos por metro cúbico ($\text{mg}\cdot\text{m}^{-3}$). Para la determinación de la turbidez se utilizó un turbidímetro especializado (2100Q Portable Turbidimeter Hach) para obtener los resultados en unidades nefelométricas de turbidez (NTU).

En la última salida de campo se midieron otros parámetros importantes de la calidad del agua, como: Temperatura °C, oxígeno disuelto, saturación de oxígeno (%),

conductividad y pH, que permitieron conocer el estado trófico del lago en el momento de las mediciones (Tabla 2).



Figura 2. Equipo utilizado en campo para la toma de muestras de agua. A la izquierda se ve un ejemplo de las botellas utilizadas, mientras que en la derecha se ve un turbidímetro de campo en la parte superior y un GPS en la parte inferior.

Tabla 1. Concentraciones de Chl-a y turbidez obtenidas de las muestras de agua de Laguna Grande.

	Oct. 24th 2022 (40 samples)		Jan. 6th 2023 (25 samples)		Mar. 1st 2023 (20 samples)	
Statistics	Chl-a <i>mg·m⁻³</i>	Turbidity <i>NTU</i>	Chl-a <i>mg·m⁻³</i>	Turbidity <i>NTU</i>	Chl-a <i>mg·m⁻³</i>	Turbidity <i>NTU</i>
Mean	4.7	2.4	3.41	1.91	6.44	7.31

Standard Deviation	0.56	0.53	0.56	0.83	1.26	4.14
Max.	6.72	3.8	4.41	3.8	8.67	20.2
Min.	3.54	1.5	2.24	0.6	3.78	2.4

Tabla 2. Valores de temperatura, oxígeno disuelto, saturación de oxígeno, conductividad y pH obtenidos en la Laguna Grande.

	Temperature (C°)	Dissolved oxygen (mg·l⁻¹)	Oxygen saturation (%)	Conductivity (mhos·cm⁻¹)	pH
Mean	21.3	7.1	78.7	118.1	7.2
Min.	20.9	6.7	76.1	115.0	6.4
Max.	21.8	8.4	87.6	119.9	7.4
Standard deviation	0.3	0.5	2.9	1.1	0.3

4.3. Medición sobre el terreno de las firmas espectrales del agua (Rrs)

Realizamos mediciones de reflectancia (Rrs) en 15 estaciones de muestreo utilizando un espectrorradiómetro ASD FieldSpec-4 (ASD Inc., Malvern Panalytical)(Anexo 1). Este instrumento está específicamente diseñado para operar en una longitud de onda que va de 350 nm a 2500 nm.

La reflectancia de teledetección por encima del agua se calculó mediante la ecuación (1):

$$Rrs = \frac{Lw(\lambda)}{Ed(\lambda)} (sr^{-1}) \quad (1)$$

Donde, Rrs = reflectancia de teledetección por encima del agua; $Lw(\lambda)$ = radiancia espectral del objetivo ($W \cdot cm^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$); $Ed(\lambda)$ = irradiancia espectral de la placa de referencia ($W \cdot cm^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$). En el estudio se utilizó una placa de referencia

Spectralon para simular una superficie lambertiana. Las mediciones se realizaron entre las 10:00 y las 13:00, una hora de condiciones óptimas con baja inclinación solar, alta energía radiante y tiempo favorable. Las medidas radiométricas siguieron los métodos establecidos por Milton (1987) y Mobley (1999), realizadas en condiciones de poco viento ($0 - 4 \text{ m}\cdot\text{s}^{-1}$), cielos despejados y ángulos solares entre 0 y 30° . Para minimizar el efecto del reflejo solar, el espectrorradiómetro se colocó con una inclinación de 40° respecto a la vertical y a 135° del sol. El sensor se colocó a 1 metro por encima de la superficie del agua. Se establecieron diez mediciones repetidas para cada estación, verificando los resultados directamente sobre el terreno. Algunos espectros anómalos causados por emisiones solares aleatorias pueden estar presentes en el resultado medido. Sin embargo, se suprimieron y los espectros restantes se promediaron (figura 3).

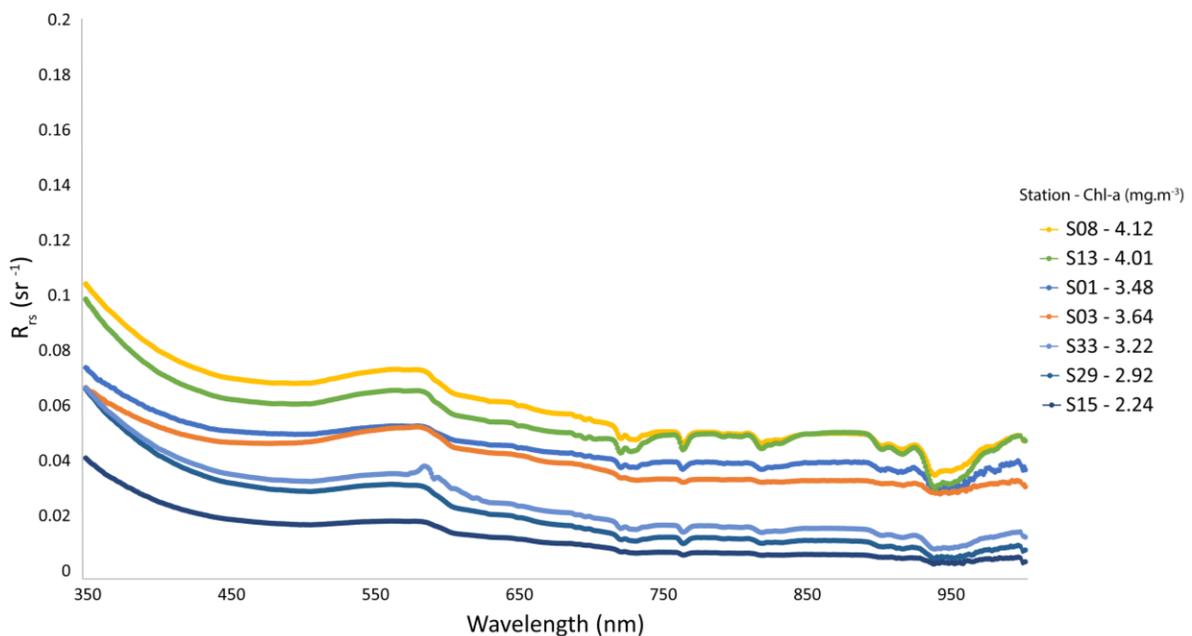


Figura 3. Espectros R_{rs} medidos in-situ con su correspondiente valor de Chl-a.

Se utilizó el software ENVI-IDL para construir una biblioteca espectral de muestras de agua superficial en diferentes condiciones de concentración de Chl-a. Esta

biblioteca espectral de siete perfiles espectrales se utilizó para evaluar el rendimiento de los diferentes métodos de corrección atmosférica en las escenas del sensor OLI L-8.

4.4. Datos de imágenes satelitales y métodos de corrección atmosférica

4.4.1. Imágenes del satélite Landsat-8 OLI

Landsat 8 es un satélite de observación terrestre que forma parte del programa Landsat, una serie de misiones espaciales de la NASA y el Servicio Geológico de los Estados Unidos (USGS). Fue lanzado el 11 de febrero de 2013, con el objetivo principal de proporcionar datos continuos y de alta calidad para el monitoreo y estudio de la superficie terrestre. En este estudio, utilizamos escenas del sensor L-8 Operational Land Imager (OLI), el cual fue desarrollado por Ball Aerospace & Technologies. Dispone de un amplio conjunto de 11 bandas espectrales que abarcan desde el espectro visible hasta el infrarrojo cercano y el infrarrojo térmico (Tabla 3). Este instrumento adquiere imágenes con una resolución espacial máxima de 15 m. La resolución varía en función de las bandas espectrales. Las bandas ópticas (Bandas 1 a 7) tienen una resolución espacial de 30 m, mientras que con la banda pancromática (Banda 8) es posible mejorar la precisión hasta los 15 m. Las bandas térmicas (Bandas 10 y 11) tienen una resolución de 100 m. Las imágenes se capturan con un intervalo de revisita de aproximadamente cada 16 días, produciendo mosaicos de imágenes que cubren un área aproximada de 170 km por 183 km para cada escena (Yépez et al., 2018).

Tabla 3. Bandas espectrales del sensor L-8 OLI y sus principales características de resolución espacial.

Band Number	Description	Wavelength (μm)	Resolution
1	Coastal / Aerosol	0.433 to 0.453	30
2	Blue	0.450 to 0.515	30

3	Green	0.525 to 0.600	30
4	Red	0.630 to 0.680	30
5	Near-infrared	0.845 to 0.885	30
6	Short wavelength infrared 1	1.56 to 1.66	30
7	Short wavelength infrared 2	2.10 to 2.30	60
8	Panchromatic	0.50 to 0.68	15
9	Cirrus	1.36 to 1.39	30
10	Long wavelength infrared 1	10.3 to 11.3	100
11	Long wavelength infrared 2	11.5 to 12.5	100

La Laguna Grande ocupa una posición geográfica en la intersección de dos órbitas, a saber, las combinaciones Path/Row 001/085 y 001/086, lo que resulta en una región de superposición que abarca aproximadamente 31 km. Cabe destacar que las imágenes de satélite utilizadas en este estudio fueron obtenidas de la página web oficial del Servicio Geológico de los Estados Unidos (USGS), concretamente de la Colección 2, Niveles 1 y 2. Se puede acceder a estas imágenes en el siguiente enlace: <https://earthexplorer.usgs.gov> (consultado el 15 de junio de 2023).

Se utilizaron tres imágenes de satélite del sensor L-8 OLI (Tabla 4) para desarrollar los modelos empíricos para recuperar los parámetros bio-ópticos, es decir, Chl-a y turbidez. Los modelos empíricos se desarrollaron mediante una combinación de la reflectancia de la señal y los datos in-situ. La diferencia temporal entre la recogida de datos in-situ y la adquisición de imágenes por satélite no supera los 3 días. No se produjeron precipitaciones durante toda la recogida de datos. Se utilizaron siete imágenes L-8 OLI adicionales para estudiar la variabilidad espaciotemporal de los parámetros bio-ópticos (Chl-a y Turbidez) en el lago durante diferentes condiciones estacionales entre ciclos hidrológicos para 2014 y 2022.

Tabla 4. Las tres imágenes del satélite L-8 OLI utilizadas para desarrollar los modelos de estimación espectral de Chl-a y turbidez.

Image ID	<i>In-situ</i> Date	Image Date	Days Differences	Path/Row
LC08_L1TP_001085_20221021_20221101_02_T1	10/24/2022	10/21/2022	±3	001/085
LC08_L1TP_001086_20230109_20230124_02_T1	01/06/2023	01/09/2023	±3	001/086
LC08_L1TP_001086_20230226_20230301_02_T1	03/01/2023	02/26/2023	±3	001/085

Tabla 5. Imágenes del satélite L-8 OLI utilizadas para estudiar la variabilidad espaciotemporal de los parámetros bio-ópticos en el lago durante diferentes condiciones estacionales entre ciclos hidrológicos para 2014 y 2022.

Image ID	Image Date	Path/Row
LC08_L1TP_001085_20140201_20200912_02_T1	02/01/2014	001/085
LC08_L1TP_001085_20140422_20200911_02_T1	04/22/2014	001/085
LC08_L1TP_001085_20140812_20200911_02_T1	08/12/2014	001/085
LC08_L1TP_001085_20141031_20200910_02_T1	10/31/2014	001/085
LC08_L1TP_001086_20220311_20220321_02_T1	03/11/2022	001/086
LC08_L1TP_001085_20220428_20220503_02_T1	04/28/2022	001/085
LC08_L1TP_001085_20220903_20220913_02_T1	09/03/2022	001/085
LC08_L1TP_001085_20221021_20221101_02_T1	10/21/2022	001/085

4.4.2. Métodos de corrección atmosférica

En esta investigación, realizamos una comparación de cuatro modelos diferentes de Corrección Atmosférica (AC) diseñados para obtener la reflectancia del agua superficial a partir de imágenes de radiancia L-8 OLI. Se utilizaron varias estaciones lacustres para comparar el rendimiento de estos cuatro modelos de corrección atmosférica:

- 1) El primer modelo probado fue ACOLITE, que es un procesador desarrollado por

RBINS (Real Instituto Belga de Ciencias Naturales) utilizado para aplicar el enfoque de AC y preprocesamiento de imágenes de satélite en aplicaciones relacionadas con aguas interiores y costeras. ACOLITE utiliza el enfoque conocido como ajuste del espectro oscuro para realizar la corrección atmosférica (Vanhellemont y Ruddick, 2018, 2021, Vanhellemont, 2019a, 2019b, 2020). El objetivo principal es eliminar las influencias atmosféricas, como la dispersión y la absorción, para mejorar la precisión de los datos de teledetección para diferentes aplicaciones. El reflejo solar (sun-glint) es la reflexión especular de la luz solar en la superficie del agua. Puede introducir errores significativos en los datos de teledetección, especialmente en las regiones costeras y oceánicas. ACOLITE incluye algoritmos para detectar y cuantificar el reflejo solar en las imágenes de satélite (Harmel et al., 2018). Una vez detectado el reflejo solar, ACOLITE aplica algoritmos de corrección para ajustar los valores de los píxeles con el fin de compensar la sobreestimación de la reflectancia causada por el efecto del reflejo solar. En este estudio se utilizó la versión v20210114.0 del procesador, y se modificó su fichero de configuración por defecto para aplicar la corrección de reflexión a la imagen, y también para obtener los resultados en formato GeoTIFF.

2) El segundo modelo fue iCOR, que es una herramienta desarrollada por De Keukelaere et al. (2018) que puede procesar datos de satélite adquiridos sobre aguas costeras, interiores o de transición y tierra. iCOR emplea el Moderate-Resolution Atmospheric Radiance and Transmittance Model-5, conocido como MODTRAN5 (Berk et al., 2006), para realizar los cálculos de transferencia radiativa. Además, utiliza Look-Up Tables (LUTs) para acelerar los procesos de estimación. Un aspecto importante de iCOR es su capacidad para identificar si un píxel pertenece a una zona acuática o terrestre, lo que le permite aplicar una corrección atmosférica específica en consecuencia (Wolters et al., 2021). La versión iCOR utilizada fue la v3.0 del software SNAP.

3) El tercer modelo fue Land Surface Reflectance Code (LaSRC) cuyo algoritmo fue desarrollado por E. Vermote (USGS, 2023), National Aeronautics and Space Administration (NASA) Goddard Space Flight Center (GSFC) y fue modificado por el

centro USGS Earth Resources Observation and Science (EROS). LaSRC genera la reflectancia de la parte superior de la atmósfera (TOA) y la temperatura de brillo de la parte superior de la atmósfera (BT) utilizando los parámetros de calibración proporcionados en los metadatos. A continuación, se aplican rutinas de corrección atmosférica a los datos de reflectancia L-8 TOA utilizando información adicional como vapor de agua, ozono y espesor óptico de aerosoles (AOT) obtenida del espectrorradiómetro de imágenes de resolución moderada (MODIS). Además, para generar la reflectancia de la superficie se utiliza el modelo digital de elevación derivado del Earth Topography Five Minute Grid (ETOPO5) (USGS, 2023). Este producto puede descargarse de la siguiente página web del USGS (<https://www.usgs.gov/landsat-missions/landsat-surface-reflectance> (última consulta: 15 de junio de 2023)). A este producto final se le aplicó una ecuación de escala (2) para normalizar los valores de reflectancia entre 0 y 1, lo que permitió compararlo con los otros métodos.

$$Rrs(\lambda) = 0.0000275 \times Pixel\ Value - 0.2 \quad (2)$$

4) El último método fue el procesador de corrección atmosférica C2RCC (Case 2 Regional CoastColour), que tiene un enfoque de aprendizaje profundo mediante un conjunto de redes neuronales entrenadas y vinculadas a datos simulados de reflectancia en masas de agua, y radiancias en la atmósfera superior. Sus principales salidas están asociadas a las propiedades ópticas inherentes (IOPs) del agua, es decir, aquellas que dependen exclusivamente de la absorción y dispersión de sus constituyentes (Brockmann et al., 2016). El método considera tres conjuntos de redes neuronales para el cálculo de la reflectancia en función del objetivo de la investigación: C2RCC-Nets (Red neuronal estándar sugerida para su uso en masas de agua eutróficas o mesotróficas), C2X-NETS (Redes neuronales especializadas las masas de agua con altas concentraciones de materia en suspensión y concentración de clorofila) y C2X-COMPLEX-Nets (sugerida principalmente para su uso en aguas continentales) (Soriano-González et al, 2022). C2RCC puede utilizarse

como complemento en el software SNAP y permite calcular la reflectancia en imágenes de satélite Sentinel 3 OLCI, Sentinel 2 MSI, Landsat-8/9, MODIS y MERIS (por ejemplo, Kyryliuk y Kratzer, 2019; Schiller y Doerffer, 1999).

4.5. Metodología de modelización de la calidad del agua

Para determinar los parámetros de calidad del agua (Chl-a y turbidez) a partir de datos in-situ y de satélite (imágenes OLI L-8), implementamos un flujo de trabajo completo (Figura 4). Esta metodología incluye los siguientes pasos principales: i) adquisición in-situ de firmas espectrales y recogida de muestras de agua, acompañada de la selección de las escenas OLI L-8 correspondientes; ii) determinación de Chl-a ($\text{mg}\cdot\text{m}^{-3}$) y turbidez (NTU), y evaluación de los modelos de corrección atmosférica; iii) identificación de los píxeles con distorsión atmosférica (altos niveles de aerosol) para evitar introducir errores externos en el modelo de estimación espectral; iv) determinación de las bandas espectrales (con índices y relaciones de bandas de reflectancia) que muestran las regresiones de mejor ajuste con los valores in-situ, en las que ACOLITE y C2RCC fueron seleccionados como los mejores modelos de corrección atmosférica para estimar los valores de Chl-a y turbidez, respectivamente; v) evaluación estadística empleando la metodología bootstrapping para mejorar el modelo de estimación espectral correspondiente a cada parámetro de calidad del agua. Además, utilizamos un conjunto de cinco métricas estadísticas distintas para determinar la precisión y exactitud del proceso de modelización; vi) generación de las imágenes espaciotemporales de los parámetros de calidad del agua en diferentes fechas y condiciones estacionales.

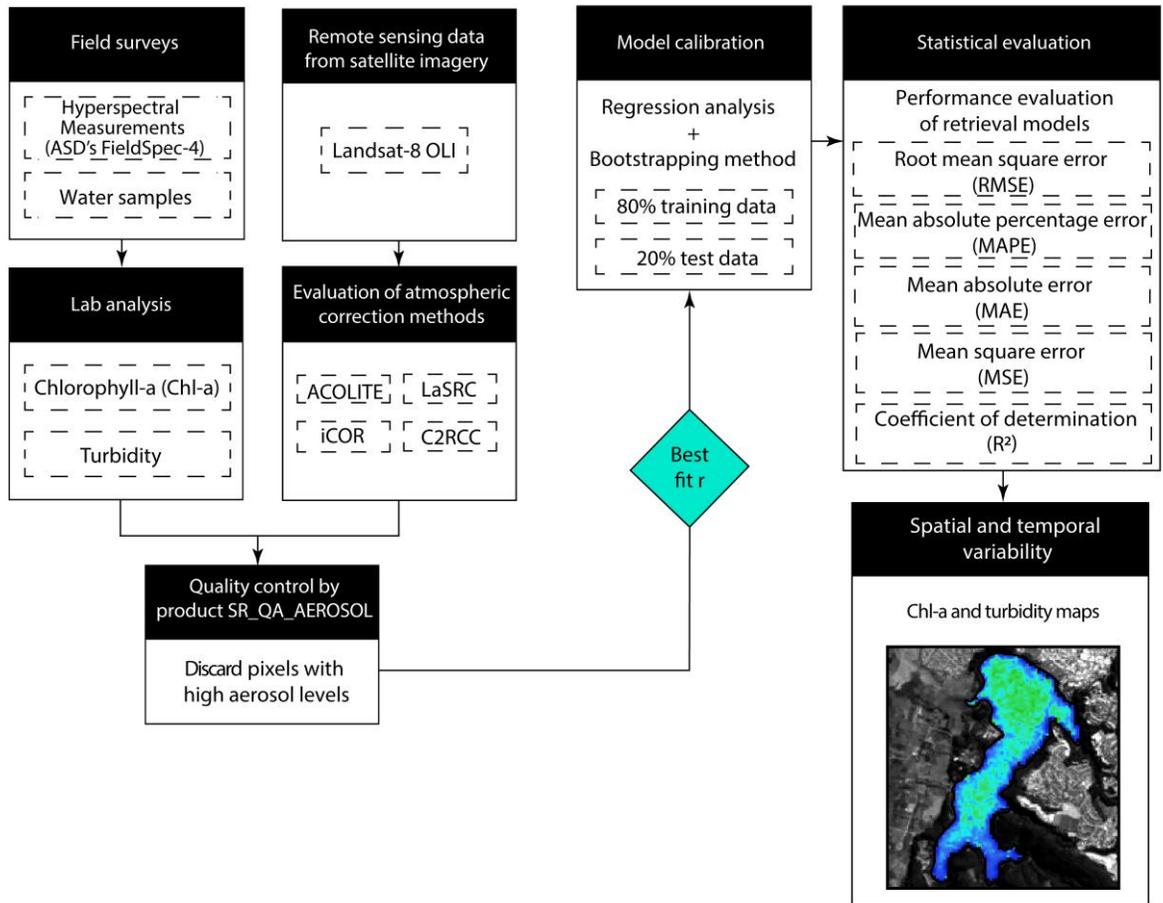


Figura 4. Flujo de trabajo para el análisis de datos de imágenes in-situ y por satélite.

4.6. Selección de índices espectrales

Los índices espectrales se utilizan para medir las características distintivas de la vegetación, las masas de agua y los distintos tipos de cubierta terrestre (Rodríguez-López et al., 2023). Los satélites de resolución baja a media se han utilizado ampliamente para aplicar algoritmos de clasificación de aguas continentales eutróficas y para recuperar la concentración de Chl-a (Dang et al., 2023). Desde el punto de vista óptico, la Chl-a presenta dos puntos de mayor reflectancia, situados en los rangos de longitud de onda del infrarrojo verde y cercano, a 550 nm y 700 nm, respectivamente (Abdelal et al., 2022). Un total de tres índices espectrales (Tabla 6) se han utilizado previamente para detectar la presencia de Chl-a en el agua mediante

teledetección.

El Índice de Vegetación de Diferencia Normalizada (NDVI) se calcula mediante la fórmula $NDVI = (B5 - B3) / (B5 + B3)$, donde "B5 - NIR" representa la reflectancia espectral del infrarrojo cercano, predominantemente influida por la reflexión del dosel vegetal, y "B3 - Rojo" significa la reflectancia dentro de la parte roja del espectro electromagnético, donde la absorción de clorofila alcanza su máximo (Raynolds et al., 2008). El Índice de Vegetación de Diferencia Normalizada Verde (GNDVI) (Gitelson et al., 1996) se basa en el concepto de que un índice diseñado para estimar el contenido de clorofila debe permanecer constante independientemente de los pigmentos distintos de la clorofila y no debe verse influido por factores externos, como el fondo o las condiciones atmosféricas (Bannari et al., 2007). Se calcula mediante la fórmula $GNDVI = (B5 - B3) / (B5 + B3)$, según la configuración de bandas del sensor OLI L-8. El Índice de Clorofila Verde (GCI) (Gitelson et al., 2003; Gitelson et al., 2006) se utiliza para evaluar el contenido de clorofila de las hojas. Al incluir las longitudes de onda del infrarrojo cercano (NIR) y del verde, proporciona una evaluación mejorada del contenido de clorofila (Rodríguez-López et al., 2020). Se calcula mediante la fórmula $GCI = (B5 / B3) - 1$.

Basamos nuestra evaluación del parámetro de turbidez en los resultados de trabajos anteriores (Baughman et al., 2015; Yépez et al., 2018; Rodríguez-López et al., 2020; Cui et al., 2022). Estos estudios han demostrado que los valores de reflectancia en las bandas roja y NIR mantienen una fuerte correlación con la concentración de sedimentos en suspensión y los niveles de turbidez. Como resultado, estas bandas espectrales se han convertido en indicadores cruciales para evaluar la turbidez en masas de agua (Cui et al., 2022). Teniendo esto en cuenta, utilizamos técnicas de análisis de regresión empírica para establecer una relación entre las mediciones de campo y los datos de satélite. Para la estimación de la turbidez (NTU) utilizamos diferentes combinaciones clásicas para este parámetro (Tabla 6), incluyendo: NIR/Rojo; NIR; Azul/Verde; Rojo+NIR; junto con el cálculo del Índice de Turbidez de Diferencia Normalizada (NDTI) (Baughman et al., 2015).

Tabla 6. Principales combinaciones de bandas e índices utilizados para estimar Chl-a y Turbidez en la Laguna Grande.

Parameter	Indices/Band combinations	Formula	Reference
Chlorophyll-a	Normalized Difference Vegetation Index (NDVI)	$(B5 - B4)/(B5 + B4)$	Raynolds et al., 2008
	Green Normalized Difference Vegetation Index (GNDVI)	$(B5 - B3)/(B5 + B3)$	Bannari et al., 2007
	Green Chlorophyll Index (GCI)	$(B5/B3) - 1$	Gitelson et al., 2006
Turbidity	Near infrared/red	$B5/B4$	Yang et al., 2017
	Near infrared	$B5$	Yepez et al., 2018
	Blue/green	$B2/B3$	Rodríguez-López et al., 2020
	Red+Near infrared	$B4+B5$	Rodríguez-López et al., 2020
	Normalized Difference Turbidity Index (NDTI)	$(B4 - B3)/(B4 + B3)$	Baughman et al., 2015
	Red	$B4$	Cui et al., 2022

4.7. Evaluación estadística

Para evaluar la eficacia de los modelos bio-ópticos seleccionados, aplicamos cinco métricas estadísticas: error medio absoluto (MAE; fórmula 3), error medio cuadrático (MSE; fórmula 4), error cuadrático medio (RMSE; fórmula 5), error medio porcentual absoluto (MAPE; fórmula 6) y el coeficiente de determinación (R^2 ; fórmula 7) comúnmente empleado. Además, para estimar la incertidumbre en nuestro análisis de correlación, empleamos la metodología bootstrapping en la evaluación de Chl-a y Turbidez obtenida mediante índices espectrales y datos in-situ. El bootstrapping consiste en crear múltiples conjuntos de datos mediante muestreo con reemplazo a partir de nuestro conjunto de datos original y, a continuación, calcular la correlación en cada uno de estos conjuntos. Bootstrapping ofrece un medio para abordar los sesgos introducidos por una muestra particular que puede no reflejar con precisión toda la población (Lee & Rodgers, 1998). Realizamos 1000 iteraciones del análisis

Bootstrap en nuestros datos, utilizando el 80% del conjunto de datos en cada iteración para calcular la correlación y el 20% restante para la validación.

$$MAE = \frac{\sum_{i=1}^N |X_i^{estimated} - X_i^{measured}|}{N} \quad (3)$$

$$MSE = \frac{1}{n} \times \sum_{i=1}^n (X_i^{estimated} - X_i^{measured})^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (X_i^{estimated} - X_i^{measured})^2} \quad (5)$$

$$MAPE = \frac{100}{n} \times \sum_{i=1}^n \left(\frac{X_i^{estimated} - X_i^{measured}}{X_i^{estimated}} \right) \quad (6)$$

$$R^2 = 1 - \frac{SS_{res}}{SS_{total}} \quad (7)$$

5. RESULTADOS

5.1. Mediciones sobre el terreno de los parámetros del agua

En total, se recogieron 85 muestras de agua en diferentes condiciones estacionales. Para la primera fase del estudio, se realizaron 40 mediciones de Chl-a y turbidez, lo que permitió la creación de mapas de concentración mediante la interpolación de estos parámetros. El objetivo era identificar las zonas del lago con niveles de concentración bajos, intermedios y altos, destacando así las áreas con mayor variabilidad en dichos valores. Esta información permitió optimizar los posteriores muestreos de campo, reduciendo el número de muestras necesarias a un rango de 20-25 estaciones. Dado que las estaciones cercanas mostraban valores similares, se utilizaron las estaciones con mayores variaciones de Chl-a y turbidez para construir el modelo de estimación espectral. Así, en las dos últimas salidas de campo, nos centramos en las estaciones y zonas del lago con mayor variabilidad de Chl-a y turbidez, para mejorar la eficiencia de nuestras mediciones en el lago. Durante estos tres muestreos de campo en 2022-2023, se registró un valor máximo

de Chl-a de $8,67 \text{ mg}\cdot\text{m}^{-3}$ en la estación cercana al otoño, mientras que los valores más bajos de Chl-a, $2,24 \text{ mg}\cdot\text{m}^{-3}$, se observaron durante la estación estival, en 2023. Los valores medios de Chl-a registrados son los siguientes: $4,7 \text{ mg}\cdot\text{m}^{-3}$ en la estación primaveral; $3,41 \text{ mg}\cdot\text{m}^{-3}$ en la estación estival; y un valor de $6,44 \text{ mg}\cdot\text{m}^{-3}$ durante la estación próxima al otoño. De acuerdo con la clasificación de Carlson de 1977, la Laguna Grande mantiene un estado mesotrófico, es decir, de productividad moderada en todas las estaciones que fueron evaluadas.

El valor máximo de turbidez se registró también en la estación cercana al otoño con un valor de 20,2 NTU, mientras que el valor más bajo se observó durante la estación de verano con 0,6 NTU. Los valores medios fueron de 2,4 NTU (temporada de primavera), 6,44 NTU (temporada de verano) y 7,31 NTU (temporada cercana al otoño). Los valores medios no superan las 5 NTU en las estaciones de primavera y verano, por lo que puede considerarse un valor de turbidez bajo, típico asociado a aguas limpias bien conservadas. Sin embargo, se observa un aumento de los valores de turbidez cerca de la estación otoñal, con valores superiores a 5 NTU, lo que representa una turbidez moderada, que podría estar relacionada con un aumento de las concentraciones de sedimentos en suspensión o de la actividad biológica.

5.2. Corrección atmosférica

5.2.1. Evaluación de los niveles de aerosoles en los puntos de las estaciones de muestreo

Se utilizaron firmas espectrales in-situ de la superficie del agua para comparar los cuatro métodos de corrección atmosférica. Para ello, se seleccionó la imagen L-8 OLI en una fecha (adquirida el 9 de enero de 2023) lo más cercana a la recogida de la biblioteca espectral del agua (6 de enero de 2023), con sólo tres días de diferencia. A continuación, se implementó el producto LaSRC SR_QA_AEROSOL para determinar qué estaciones de muestreo son adecuadas para comparar los datos in-situ con las combinaciones de bandas de reflectancia (Figura 5).

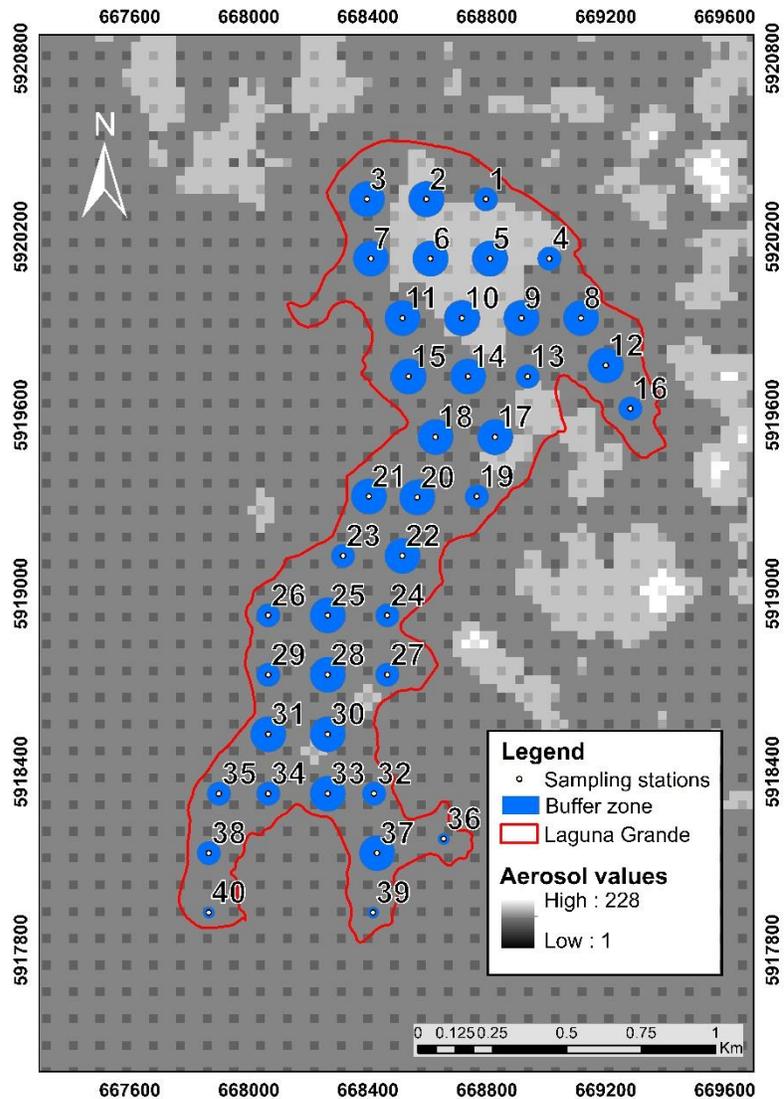


Figura 5. Las estaciones de muestreo de Chl-a y turbidez se localizan sistemáticamente cubriendo un buffer de 60, 40 y 20 m sobre la imagen de calidad del modelo LaSRC, que representa los niveles de aerosol en la escena (aplicando sólo un buffer de 40 y 20 m a aquellas estaciones cercanas a la orilla del lago). Obsérvese que las estaciones situadas en píxeles con altos valores de aerosol se excluyen del proceso de correlación.

Tabla 7. Adaptación de la tabla de valores SR_QA_AEROSOL de Landsat 8-9.

Attribute	Pixel Value
Low-level aerosol	66, 68, 96, 100
Medium-level aerosol	130, 132, 160, 164
High-level aerosol	192, 194, 196, 224, 228

El tratamiento de los datos comenzó con la localización de los puntos de las estaciones en el mapa. Para extraer los valores de reflectancia de la escena, se calcularon zonas tampón alrededor de cada estación. Estas zonas tienen distintos tamaños, de 60, 40 y 20 metros de diámetro, en lugar de una señal puntual, lo que mejora la representatividad de la reflectancia. En el caso de las estaciones situadas cerca de la orilla, aplicamos un tamaño de búfer coherente de 40 y 20 metros para evitar el contacto con la orilla del lago. Este ajuste pretendía mitigar la mezcla espectral entre las señales de reflectancia procedentes del agua y de los materiales del suelo, para evitar interpretaciones erróneas en nuestro modelo. El producto SR_QA_AEROSOL de LaSRC se utilizó para seleccionar aquellos píxeles que no se ven afectados por altos valores de aerosol, asegurando mejores correlaciones entre los datos in-situ y los resultados de las combinaciones de bandas (Tabla 7).

5.2.2. Evaluación de los métodos de corrección atmosférica

La figura 6, muestra la evaluación de diferentes métodos de corrección atmosférica, utilizando la estación 15 como referencia "limpia" sin contaminación por aerosoles. Comparamos cuatro métodos de corrección atmosférica: ACOLITE, iCOR, LaSRC y C2RCC. En nuestro análisis, excluimos las bandas SWIR del sensor OLI y nos centramos en las bandas, como la costera, azul, verde, roja y NIR, que son las longitudes de onda más sensibles para la estimación de Chl-a y Turbidez. La línea negra representa la reflectancia medida de la superficie del agua en la estación 15, que se recogió utilizando el espectrorradiómetro ASD Field-Spec 4.

Aunque para esta comparación se utilizaron siete estaciones de recogida de datos, en los resultados sólo se muestra la estación 15 con fines ilustrativos. La línea roja segmentada, que corresponde a la firma espectral del modelo LaSRC, parece más cercana a la reflectancia real (línea negra). Sin embargo, en este modelo destaca una sobreestimación en los datos B3 (verde) y B5 (NIR), a diferencia de los otros modelos de corrección atmosférica. Esto indica que el modelo LaSRC no tiene en cuenta el efecto del reflejo solar sobre la superficie del agua.

La comparación de los resultados de satélite y de campo mostró que ACOLITE (línea segmentada cian) arrojaba resultados más alineados con las mediciones de campo sin destellos. Aunque los valores en todas las bandas son ligeramente inferiores a la firma de reflectancia real, éstos mantienen una forma similar a la línea negra, al igual que el método LaSRC, pero sin saturación en B3 (Verde) y B5 (NIR). Es importante señalar que estas bandas Verde e Infrarrojo Cercano son esenciales para la creación de modelos de estimación de Chl-a. Esto se debe a que la Chl-a absorbe la luz en las regiones azul y roja del espectro electromagnético, mientras que refleja la luz en las regiones verde e infrarroja cercana (Johan et al., [50]). Esta propiedad nos permite estimar la concentración de Chl-a en el agua examinando la relación de reflectancia entre las bandas verde e infrarroja cercana. iCOR (línea segmentada naranja) y C2RCC (línea segmentada púrpura) mostraron valores inferiores en comparación con la reflectancia real, e incluso con los modelos LaSRC y ACOLITE en todas las bandas. C2RCC mostró un valor bajo en la costa B1 con respecto a iCOR, lo que podría indicar una sobrecorrección en esta longitud de onda utilizando este modelo. En general, ambos modelos (iCOR y C2RCC) presentan una subestimación en los valores de reflectancia. Por lo tanto, hemos elegido ACOLITE como la opción óptima para avanzar en nuestro análisis en la modelización de la estimación de Chl-a y Turbidez.

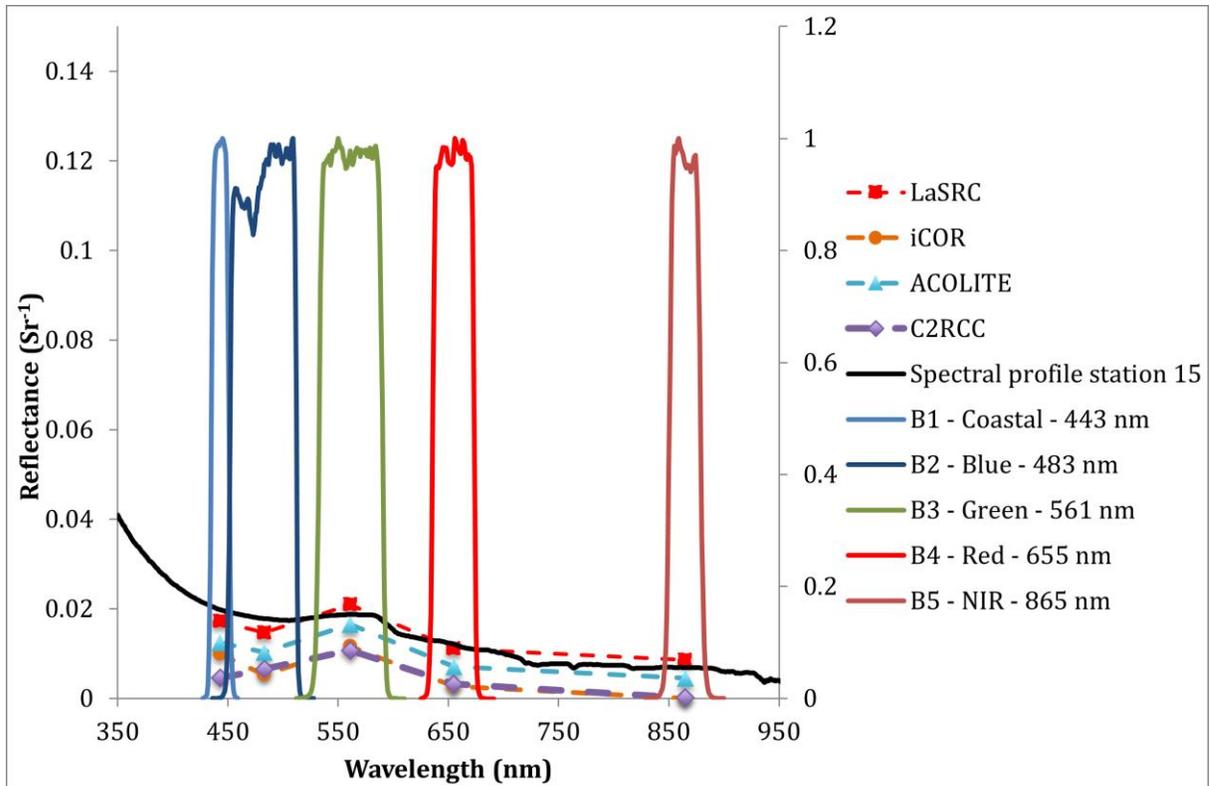


Figura 6. Comparación de los resultados de la corrección atmosférica y los datos del radiómetro de campo para la Laguna Grande. La línea negra representa la reflectancia real en la superficie del agua utilizada en el análisis comparativo como referencia.

Tabla 8. Modelos de estimación de la Chl-a y de turbidez para cada método de corrección atmosférica analizado (modelos de Excel sin aplicar Bootstrapping).

AC processor	Chlorophyll-a Best model	R ²	Turbidity Best model	R ²
Acolite	$Chl-a = 2.0709e^{-1.337((B5 / B3) - 1)}$	0.81	$NTU = 0.5082e^{128.79(B4+B5)}$	0.84
LaSRC	$Chl-a = 0.7462((B5/ B3) - 1) + 1.2622$	0.76	$NTU = 0.8314e^{110.13(B4)}$	0.59
C2RCC	$Chl-a = 45.78((B5 - B3)/(B5 + B3)) + 48.591$	0.75	$NTU = 1.5604e^{126.08(B4+B5)}$	0.80
iCOR	$Chl-a = -3.3504((B5/ B3) - 1) + 2.128$	0.07	$NTU = 1.785e^{92.615(B4+B5)}$	0.86

5.3. Modelos empíricos de estimación de Chl-a y turbidez

5.3.1. Análisis de estimación de Chl-a

Antes de analizar la señal de reflectancia de la imagen de satélite OLI, comparamos los datos de Chl-a in-situ con las 15 mediciones de la señal de la superficie del agua, adquiridas mediante el espectrorradiómetro ASD FieldSpec-4. Se calcularon los coeficientes de correlación R^2 para examinar la relación espectral entre la concentración de Chl-a y la reflectancia en la laguna (Figura 7). El coeficiente de determinación (R^2) varió en el rango de longitudes de onda de 350 a 1000 nm. Los valores R^2 obtenidos fueron superiores a 0,6 en la región roja a partir de 650 nm, lo que significa que la relación entre la concentración de Chl-a y la reflectancia de estas longitudes de onda son las mejores. Los valores R^2 mostraron un notable descenso en torno a 925-950 nm (una región de longitud de onda superior al NIR), pero esos valores repuntaron rápidamente hasta 0,66, incluso en longitudes de onda cercanas a 1000 nm.

La Chl-a tiene una banda de absorción única que varía con su concentración, lo que permite detectar firmas espectrales específicas mediante teledetección. Los datos revelan que los valores absolutos en las longitudes de onda de 655-880 nm y 990 nm presentan los valores más altos de R^2 . Esto sugiere una mayor correlación entre la concentración de Chl-a y la reflectancia en estas longitudes de onda específicas. En la Figura 8, los valores R^2 obtenidos para la relación entre la concentración de Chl-a in-situ y los valores de reflectancia a 655 nm y 880 nm son 0,6 y 0,656, respectivamente. Estos coeficientes indican una correlación importante en estas bandas espectrales, que se alinean estrechamente con las regiones roja e infrarroja cercana (NIR) del espectro electromagnético.

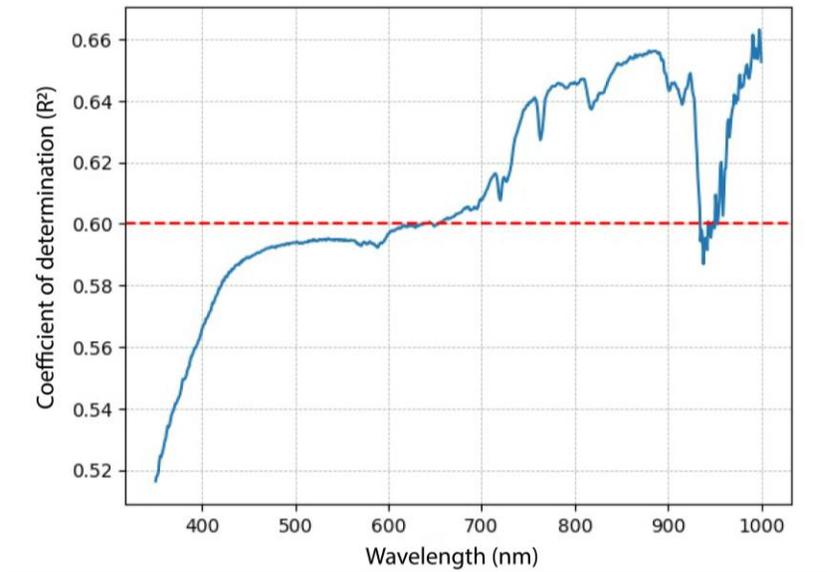


Figura 7. Correlación entre la reflectancia de la superficie del agua (perfiles espectrales) y la concentración de Chl-a obtenida durante el estudio de campo del 6 de enero de 2023.

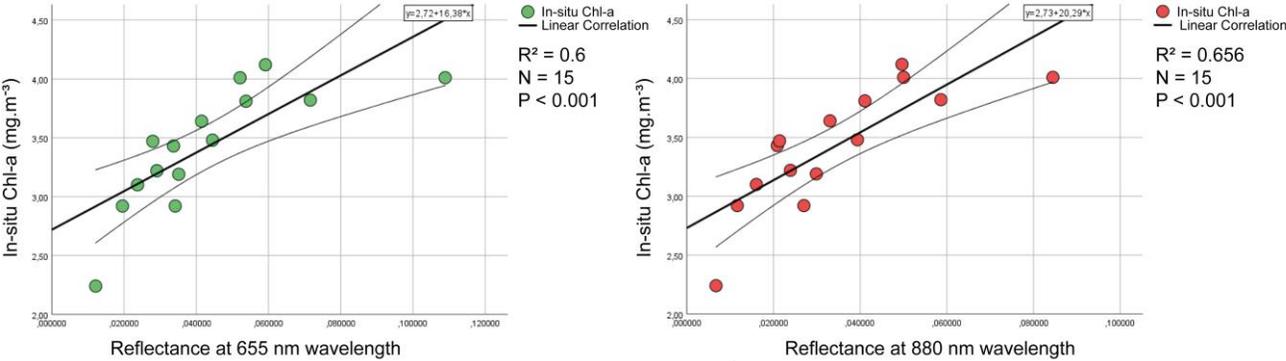


Figura 8. Relación entre la concentración de Chl-a y la reflectancia a las longitudes de onda de 655 nm y 880 nm.

Los valores del coeficiente de Pearson se utilizaron para evaluar la relación entre tres índices de vegetación y clorofila, es decir, NDVI, GNDVI y GCI, y los valores de concentración de Chl-a, utilizando datos de las regiones verde, roja y NIR. La figura 9, muestra un mapa de calor con los valores del coeficiente de Pearson de estos tres índices espectrales. En particular, estos índices (NDVI, GNDVI y GCI) mostraron una

correlación estadísticamente significativa ($p \leq 0,001$), con valores del coeficiente de Pearson de -0,87 para NDVI y GNDVI, y de -0,88 para GCI. Por lo tanto, se seleccionó GCI como la mejor opción para construir el modelo de estimación. La sensibilidad de la concentración de Chl-a a las combinaciones de reflectancia multibanda queda claramente demostrada en la Figura 9, destacando su mayor capacidad de respuesta en comparación con la reflectancia monobanda.

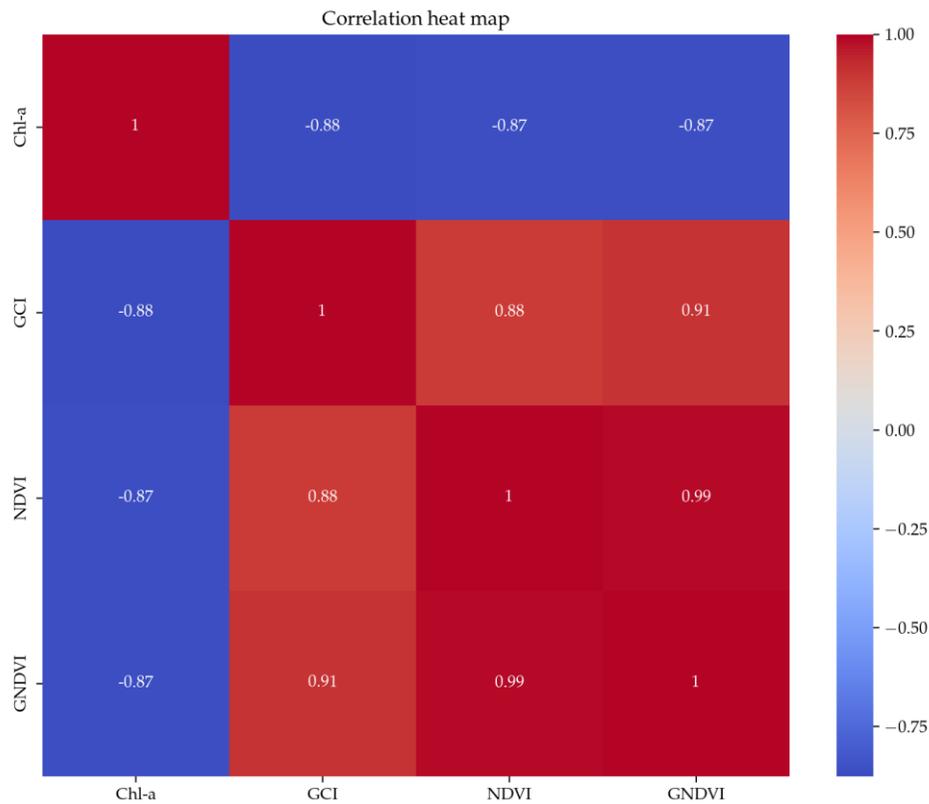


Figura 9. Mapa de calor utilizado para evaluar diferentes índices espectrales (GCI, NDVI y GNDVI) con datos de Chl-a in-situ ($\text{mg}\cdot\text{m}^{-3}$), utilizando valores de reflectancia de ACOLITE.

5.3.2. Análisis de estimación de la turbidez

La estimación de la turbidez mediante imágenes de satélite se basó en índices espectrales y combinaciones de bandas relacionadas con el material en suspensión en el agua. Se evaluaron varios índices espectrales y combinaciones de bandas: NIR, Rojo, NIR/Rojo, Rojo+NIR, Azul/Verde y NDTI para determinar el mejor ajuste con los valores de turbidez (Figura 10). Los valores obtenidos de menor a mayor fueron: NIR (Coeficiente de Pearson = 0,098); NIR/Rojo (Coeficiente de Pearson = -0,34); NDTI (Coeficiente de Pearson = 0,62); Azul/Verde (Coeficiente de Pearson = -0,87); Rojo (Coeficiente de Pearson = 0,87); y Rojo+NIR (Coeficiente de Pearson = 0,88). Los índices espectrales con mejor rendimiento fueron Azul/Verde, Rojo y, sobre todo, Rojo+NIR, que mostraron una correlación estadísticamente significativa ($p \leq 0,001$), con un valor de coeficiente de Pearson de 0,88.

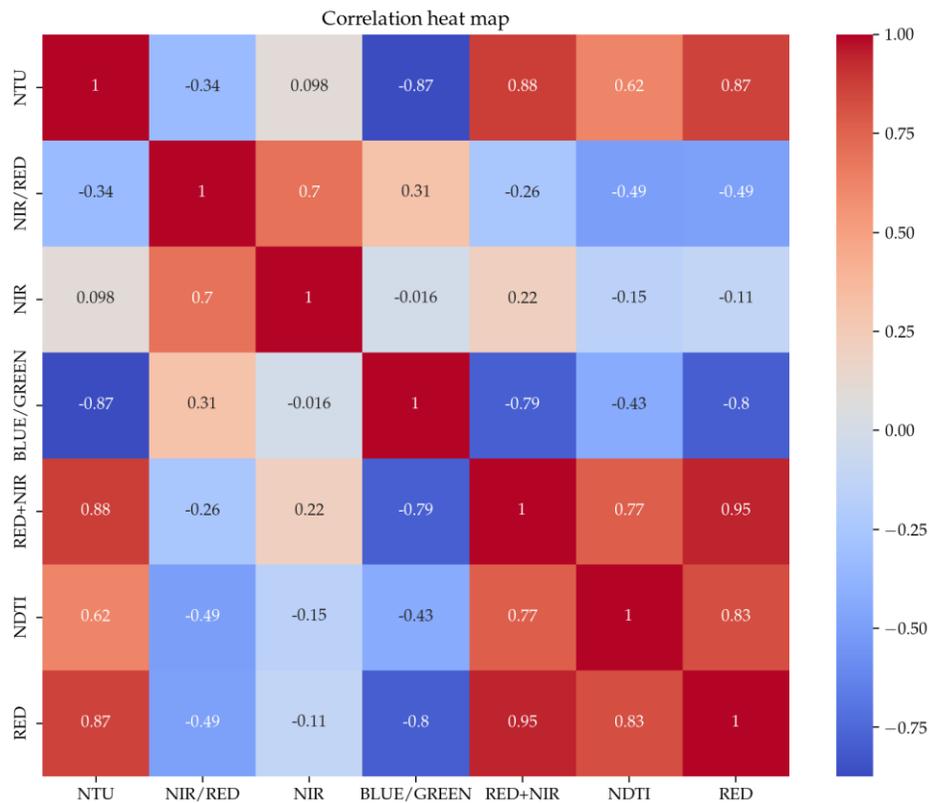


Figura 10. Mapa de calor utilizado para evaluar diferentes combinaciones de bandas (Rojo, NDTI, Rojo+NIR, Azul/Verde, NIR, NIR/Rojo y NDTI) con datos de turbidez in-situ (NTU) utilizando reflectancia ACOLITE.

5.5. Evaluación estadística y solidez del modelo

5.5.1. Evaluación estadística y robustez del modelo de estimación de Chl-a

Para evaluar la fiabilidad de nuestro análisis de correlación entre la concentración de Chl-a y el índice GCI (R^2 de mejor ajuste), aplicamos una técnica de bootstrapping. A través de 1000 iteraciones, se obtuvo la distribución de los parámetros de la función para optimizar la selección de estos entre la media y la mediana (Figura 11). En consecuencia, la ecuación 8 representa el modelo final de estimación de Chl-a.

$$Chl - a = 1.97 \times e^{(-1.46 \times GCI)} \quad (8)$$

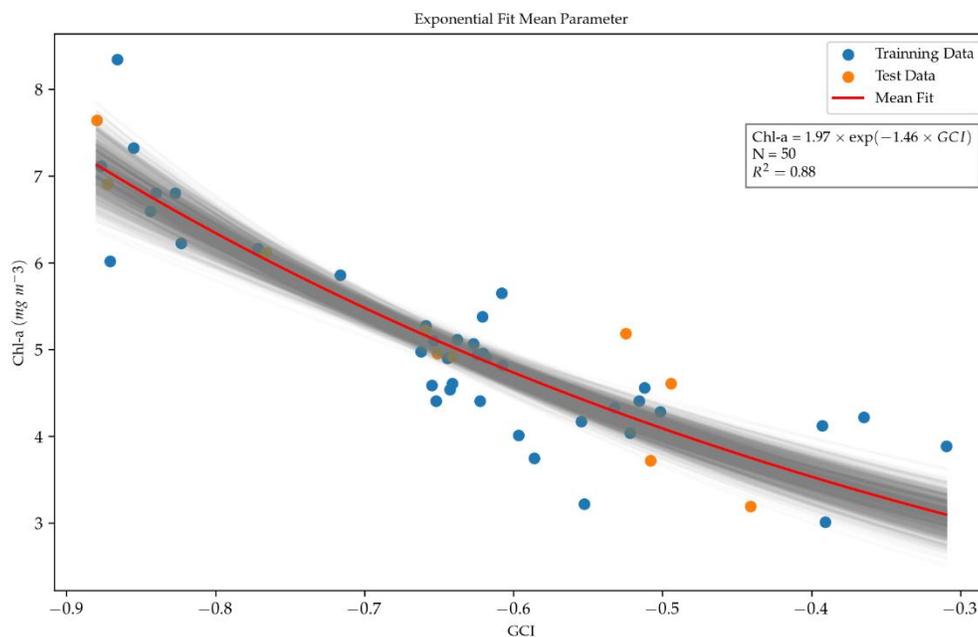


Figura 11. Curva de calibración entre los datos de Chl-a in-situ y el índice GCI con la aplicación de la técnica bootstrapping, utilizando el ajuste medio en los parámetros con 1000 iteraciones, tomando el 80% del conjunto de datos en cada iteración para calcular la correlación y el 20% restante para la validación.

Las métricas estadísticas y de correlación arrojaron resultados sólidos con un $R^2 = 0,88$ y $MAE = 0,35\%$; $MSE = 0,20$; $RMSE = 0,45\%$ y $MAPE = 7,56\%$, lo que garantiza la estabilidad de la relación observada (Figura 12; Anexo 2). Este enfoque de bootstrapping contribuyó a proporcionar una estimación sólida y fiable de la relación entre las variables.

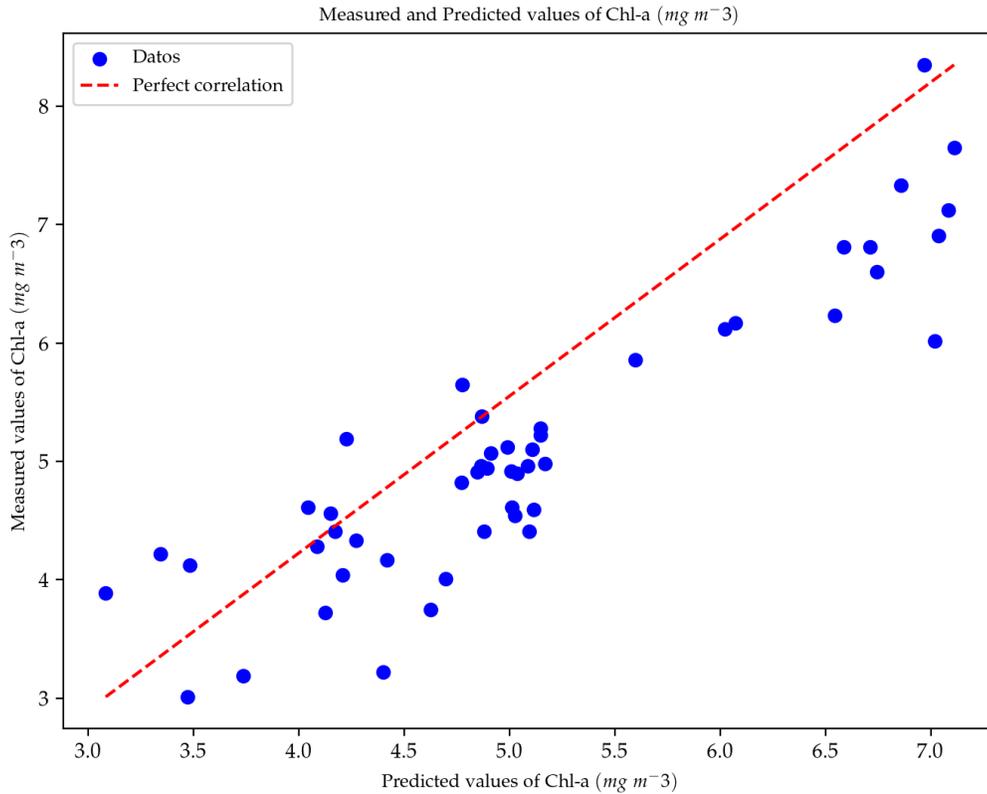


Figura 12. Comparación de Chl-a medido frente a Chl-a estimado a partir de imágenes Landsat-8 OLI utilizando el algoritmo GCI (ecuación 8) con datos ACOLITE (reflectancia corregida).

Para evaluar las tendencias en los errores de estimación, examinamos los residuos del modelo utilizando gráficos de dispersión frente a los datos de recogida in-situ. No surgió ningún patrón discernible, lo que indica la ausencia de tendencias sistemáticas en las variaciones residuales asociadas a los cambios en la concentración de Chl-a; en otras palabras, los errores parecen estar distribuidos aleatoriamente (Figura 13). Es evidente que los residuos están uniformemente dispersos alrededor de cero, con todos los errores residuales trazados aproximadamente dentro del rango de -1 a 1.

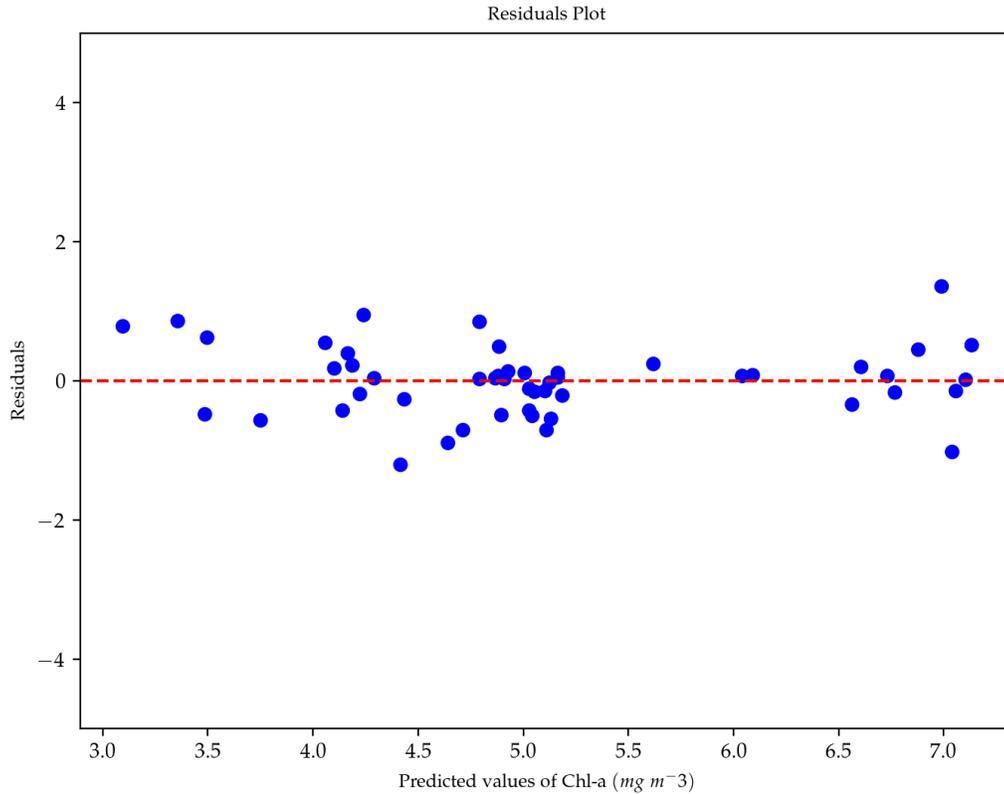


Figura 13. Valores residuales de Chl-a frente a valores predichos de Chl-a ($mg\cdot m^{-3}$), mostrando una baja dispersión en los valores en todo el rango de Chl-a, de 3 a 8 $mg\cdot m^{-3}$.

Además, se realizó un análisis de normalización de los datos, en el cual se pudo visualizar la simetría de los gráficos con el fin de determinar si se utilizaba la media o la mediana para el resto de los análisis (Figura 14). En este caso se decidió utilizar la media.

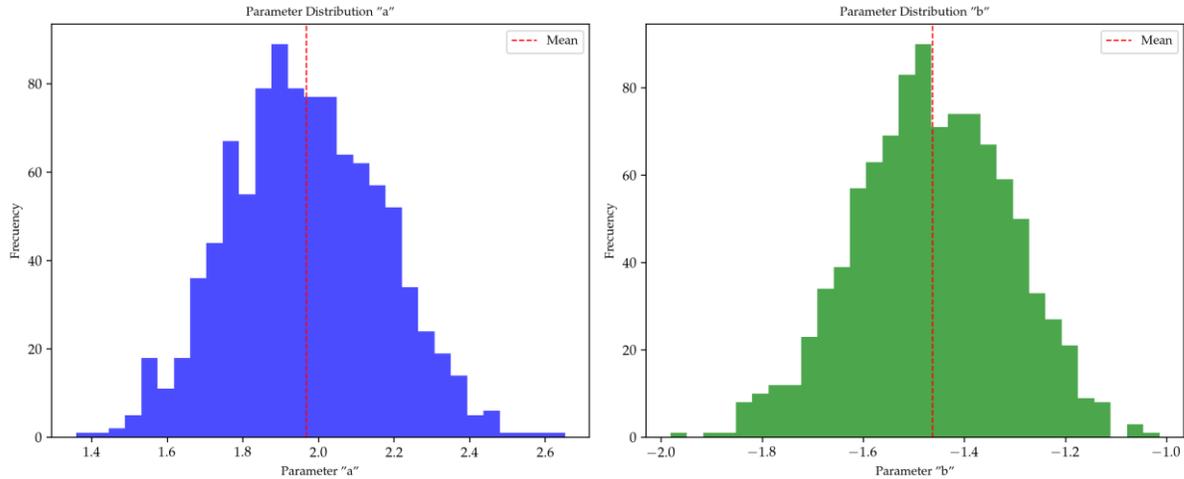


Figura 14. Distribución de la media del parámetro “a” (controla la amplitud que puede alcanzar la función exponencial) y del parámetro “b” (controla la tasa de crecimiento) para el caso de Chl-a utilizando el índice espectral GCI, con el procesador Acolite.

5.5.2. Evaluación estadística y solidez del modelo de estimación de la turbidez

De forma similar al modelo de estimación de Chl-a, se realizó el método bootstrapping utilizando 1000 iteraciones, para optimizar la selección de los parámetros de la función entre la media y la mediana (Figura 15). Como resultado, la ecuación 9 sirve ahora como modelo final de estimación de la turbidez.

$$Turbidity = 0.51 \times e^{(130.75 \times (Red + NIR))} \quad (9)$$

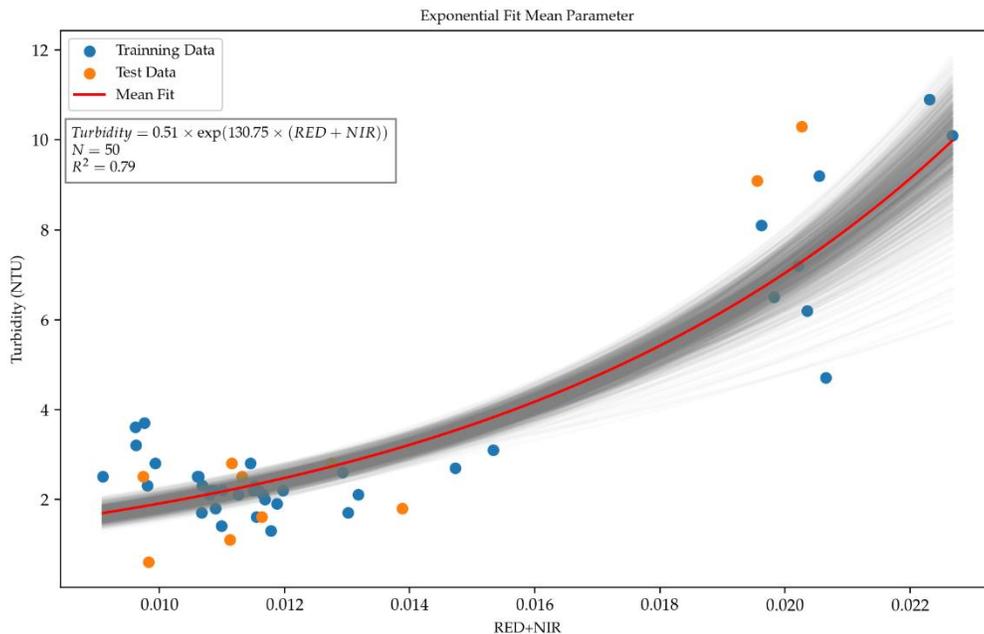


Figura 15. Curva de calibración entre los datos de turbidez in-situ (NTU) y el índice Red+NIR con la aplicación de la técnica bootstrapping utilizando el ajuste medio en los parámetros con 1000 iteraciones, utilizando el 80% del conjunto de datos en cada iteración para calcular la correlación y el 20% restante para la validación.

Las métricas estadística y de correlación también arrojaron resultados intermedios con $R^2 = 0,79$; $MAE = 1,15\%$; $MSE = 2,11$; $RMSE = 1,45\%$ y $MAPE = 54,89\%$ (Figura 16; Anexo 2). Los últimos resultados MAPE son insatisfactorios, ya que el error supera el 10-20%. Debido a esto, se realizaron dos pruebas más con distintos métodos de corrección atmosférica (iCOR y C2RCC) con el fin de analizar si es que el MAPE se reducía utilizando la técnica bootstrapping, pero los resultados no mejoraron con respecto al primer modelo (Anexo 2.1.). Esto sugiere que la correlación entre el índice Red+NIR y los datos de turbidez in-situ no es lo suficientemente sólida como para considerarla un modelo de estimación fiable.

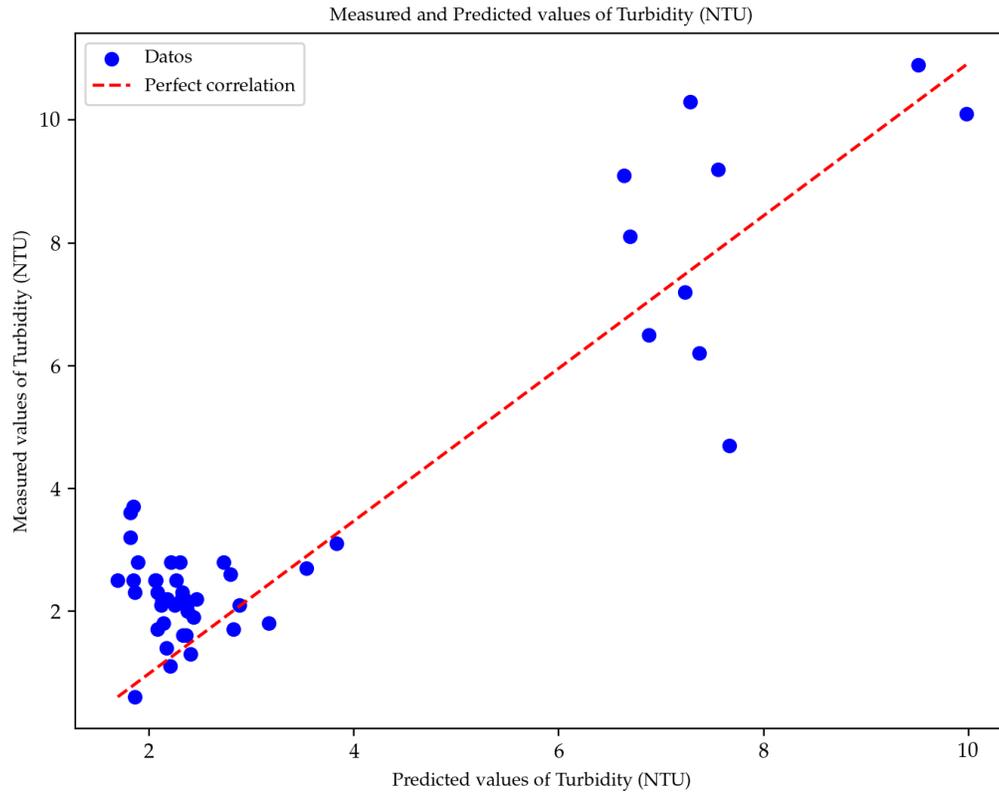


Figura 16. Comparación de la turbidez medida frente a la turbidez estimada a partir de imágenes Landsat-8 OLI utilizando el algoritmo Red+NIR (ecuación 9) con datos ACOLITE (reflectancia corregida).

La figura 17 muestra una agrupación de datos, con un grupo con valores muy bajos (< 4 NTU) y otro grupo más disperso con valores ligeramente superiores (> 7 NTU) de 7 a 10 NTU, lo que sugiere un comportamiento estacional en los datos.

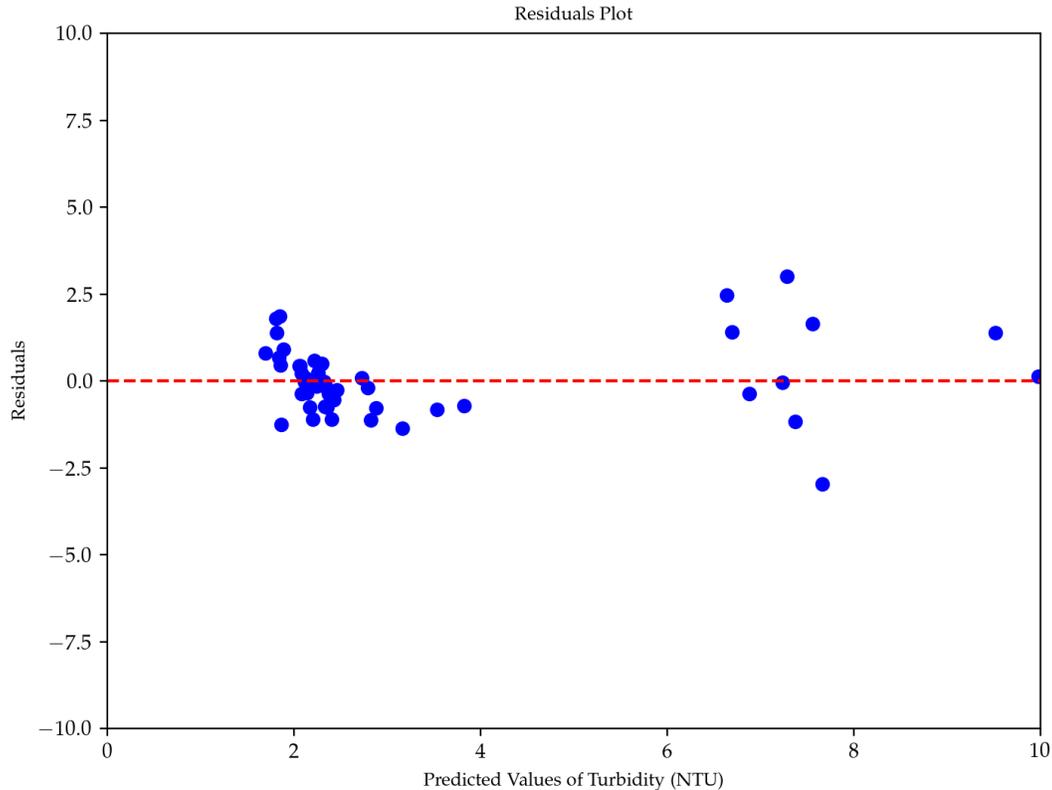


Figura 17. Los residuos de las observaciones de turbidez in-situ comparados con los valores de turbidez previstos (NTU). Obsérvese que los datos no se dispersan uniformemente en torno a cero, y que todos los errores residuales se sitúan aproximadamente en el intervalo de -3,5 a 3,5 NTU.

Es importante señalar que los niveles de turbidez en este lago son particularmente más bajos que para los lagos altamente eutróficos (Silvoso et al., 2011). Estos bajos valores de turbidez pueden dar lugar a una relación espectral relativamente débil con las bandas de reflectancia.

Al igual que la Chl-a, se realizó un análisis de normalización de los datos, en el cual se pudo visualizar la simetría de los gráficos con el fin de determinar si se utilizaba la media o la mediana para el resto de los análisis (Figura 18). En este caso se pudo observar una asimetría notable, lo cual puede tener relación directa con los

insuficientes resultados estadísticos para este modelo.

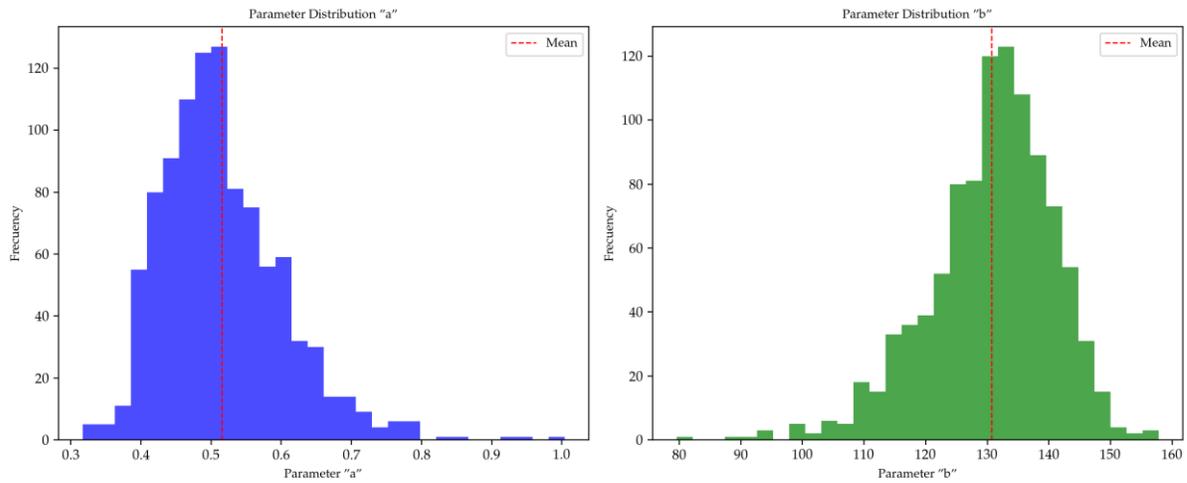


Figura 18. Distribución de la media del parámetro “a” (controla la amplitud que puede alcanzar la función exponencial) y del parámetro “b” (controla la tasa de crecimiento) para el caso de turbidez utilizando la combinación de bandas Red + NIR, con el procesador Acolite.

5.6. Variabilidad espacial y temporal

Los resultados estadísticos indican una fuerte correlación ($R^2 = 0,88$) para el modelo de estimación de Chl-a utilizando el índice GCI, pero el modelo de estimación de turbidez no reprodujo con exactitud los datos in-situ. Los mapas se realizaron de todas formas, pero debido a la estadística entregada por los análisis, no se puede interpretar que los que se visualiza se acerque a la realidad (Anexo 4). En consecuencia, nos centramos en la distribución de Chl-a para analizar retrospectivamente la variabilidad de los datos en todo el lago. La Figura 19, muestra los mapas de distribución de la concentración de Chl-a obtenidos a partir de nuestro modelo entrenado (ecuación 8) para diferentes estaciones en dos periodos: 2022 (Figura 19 a-d) y 2014 (Figura 19 e-h).

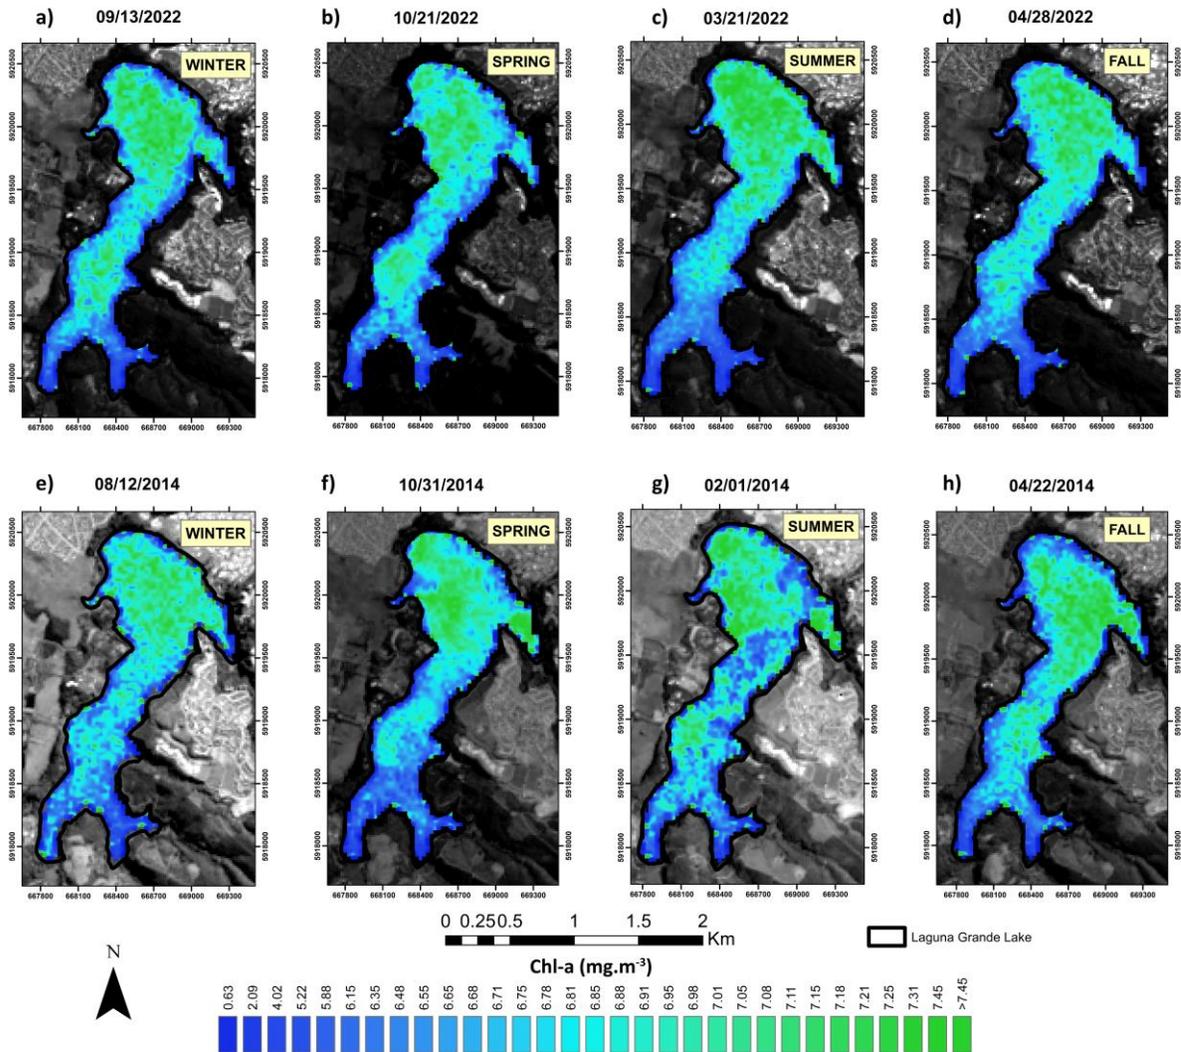


Figura 19. Mapas de distribución de Chl-a para el Lago Laguna Grande mostrando los cambios de concentración a lo largo de las estaciones de Invierno, Primavera, Verano y Otoño en 2022 (a-d) y 2014 (e-h), permitiéndonos evaluar las fluctuaciones estacionales.

Los datos del sistema de la Laguna Grande se sitúan sistemáticamente dentro de la clasificación mesotrófica, con niveles de concentración de Chl-a que oscilan entre 3 y 10 $\text{mg}\cdot\text{m}^{-3}$ (Figura 20). Estos valores implican un nivel moderado de productividad biológica, que ha permanecido estable a lo largo de varias estaciones y periodos.

Un análisis detallado de los datos de 2022 revela valores medios de Chl-a

fluctuantes. Comienzan en $6,2 \text{ mg}\cdot\text{m}^{-3}$ en invierno, descienden a $5,1 \text{ mg}\cdot\text{m}^{-3}$ en primavera, aumentan a $5,4 \text{ mg}\cdot\text{m}^{-3}$ en verano y alcanzan un máximo de $7,1 \text{ mg}\cdot\text{m}^{-3}$ en otoño (Figura 20). Este patrón es consistente tanto en la zona norte (Figura 20a) como en la zona sur (Figura 20b) del lago. Sin embargo, en la parte sur, los valores medios son sistemáticamente más bajos en cada estación: $5,5 \text{ mg}\cdot\text{m}^{-3}$, $4,6 \text{ mg}\cdot\text{m}^{-3}$, $5,2 \text{ mg}\cdot\text{m}^{-3}$ y $6,2 \text{ mg}\cdot\text{m}^{-3}$, respectivamente (Figura 20b).

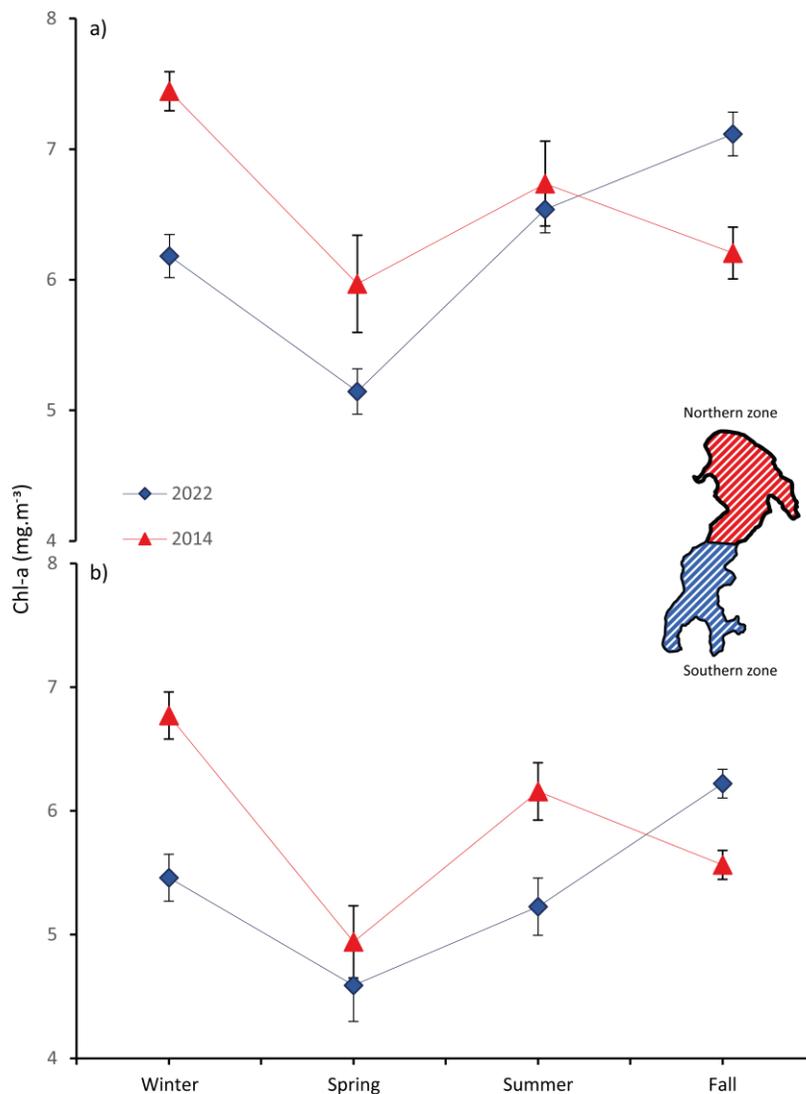


Figura 20. Diagrama de araña que ilustra la variabilidad de Chl-a a lo largo de las estaciones en las zonas norte (a) y sur (b). Se representan los valores medios de

2022 (línea azul) y 2014 (línea roja), resaltando la región de interés dentro de cada sección lacustre.

Un examen de la variación de los niveles de Chl-a en el año 2014 revela patrones distintos. En la zona norte, los valores de Chl-a oscilaron entre $7,4 \text{ mg}\cdot\text{m}^{-3}$ en invierno, disminuyeron a $6,0 \text{ mg}\cdot\text{m}^{-3}$ en primavera, alcanzaron un peak de $6,7 \text{ mg}\cdot\text{m}^{-3}$ en verano y luego disminuyeron a $6,2 \text{ mg}\cdot\text{m}^{-3}$ en la temporada de otoño (Figura 20a). Mientras tanto, la zona sur mostró una tendencia similar, aunque con valores medios sistemáticamente más bajos. Comenzando en $6,8 \text{ mg}\cdot\text{m}^{-3}$, las concentraciones de Chl-a disminuyeron hasta $5,0 \text{ mg}\cdot\text{m}^{-3}$, aumentaron hasta $6,2 \text{ mg}\cdot\text{m}^{-3}$, y luego disminuyeron de nuevo hasta $5,6 \text{ mg}\cdot\text{m}^{-3}$ (Figura 20). Este análisis comparativo proporciona información valiosa sobre la dinámica estacional de Chl-a en las regiones septentrional y meridional, arrojando luz sobre la evolución de estos patrones a lo largo del tiempo.

Los valores de Chl-a muestran sistemáticamente niveles más altos en la zona norte que en la zona sur, independientemente del año considerado (2022 frente a 2014; Figura 20). Esta disparidad puede atribuirse a un impacto antrópico más pronunciado en la zona norte, caracterizada por una rápida expansión urbana en los últimos años, mientras que la zona sur, rodeada de vegetación densa, ha permanecido relativamente inalterada. Las recientes normativas aplicadas por las autoridades locales para restringir las actividades que contribuyen a la contaminación del lago han reforzado aún más esta tendencia. Cabe destacar que los valores de Chl-a para 2022, son inferiores a los observados en 2014, en consonancia con las restricciones gubernamentales al acceso al lago, como el uso de embarcaciones propulsadas por combustible y nuevas construcciones en torno a la orilla del lago.

En un examen más detallado, al comparar los datos de verano y otoño de 2014, se observa una tendencia anticipada: una disminución de los valores de Chl-a de $6,2 \text{ mg}\cdot\text{m}^{-3}$ a $5,6 \text{ mg}\cdot\text{m}^{-3}$ (Figura 20). Esto se alinea con la disminución esperada de la temperatura entre las dos estaciones. Sin embargo, al analizar los datos de 2022 (Figura 20) se observa un patrón opuesto: los valores de Chl-a en otoño superan a

los de verano. Este comportamiento inesperado puede atribuirse al hecho de que las temperaturas otoñales recientes se asemejan a las temperaturas estivales históricas, posiblemente impulsadas por la variabilidad climática regional. Estos resultados ponen de manifiesto el potencial del sensor OLI para predecir la distribución de las floraciones de algas y el estado trófico del lago.

6. DISCUSIÓN Y CONCLUSIONES

Nuestros principales hallazgos en el desarrollo de modelos de estimación espectral para los parámetros de calidad del agua en la Laguna Grande pueden clasificarse en tres aspectos clave:

i) Aplicación de métodos de corrección atmosférica

Realizamos el primer estudio de calidad del agua en Laguna Grande aplicando una metodología innovadora, que implica la recogida de datos in-situ (parámetros de calidad del agua) combinados con firmas espectrales en la superficie del agua utilizando radiómetros terrestres. A continuación, estas mediciones se integraron para calibrar y validar la señal de reflectancia de las imágenes multiespectrales de satélite (sensor OLI) utilizando diferentes métodos de corrección atmosférica. ACOLITE proporcionó resultados que coincidían estrechamente con las mediciones de campo sin destellos. Aunque los valores en todas las bandas eran ligeramente inferiores a las firmas de reflectancia reales (perfil espectral del agua superficial), conservaban una forma similar. Al comparar los datos in-situ de Chl-a y turbidez con las señales de reflectancia corregidas por los distintos métodos atmosféricos evaluados, ACOLITE mostró los mayores coeficientes de determinación, alcanzando valores R^2 de 0,88 y 0,79 para Chl-a y turbidez, respectivamente. Estos resultados están en línea con un estudio reciente de Rodríguez-López et al. 2020, que utilizó ACOLITE como método de mitigación de la distorsión atmosférica en escenas L-8 OLI para estimar las concentraciones de Chl-a en el Lago Llanquihue (sur de Chile).

Otras investigaciones sobre calidad del agua han encontrado que ACOLITE corrige eficazmente las distorsiones atmosféricas en masas de agua, especialmente en el desarrollo de modelos de estimación de Chl-a a partir de escenas OLI de satélite L-8 (por ejemplo, Smith et al., 2021; Asim et al., 2022; y Pahlevan et al., 2022). Además, nuestro estudio confirma el papel esencial de una corrección atmosférica rigurosa para mitigar los errores de los aerosoles y el efecto de los reflejos solares durante la construcción de modelos de inversión espectral a partir de imágenes de satélite. Como se discute en Yépez et al., 2018, la utilización del producto USGS LaSRC SR_QA_AEROSOL ayuda a filtrar los píxeles afectados por distorsiones atmosféricas, mejorando la relación entre los datos in-situ y la reflectancia de la imagen, incluso en casos de disparidades temporales entre la toma de datos y la adquisición de la escena.

ii) Desarrollo de un modelo empírico de estimación

El Índice de Clorofila Verde (GCI) fue seleccionado como la elección óptima para construir el modelo de estimación de Chl-a en la Laguna Grande, a pesar de ser un índice espectral utilizado en aplicaciones terrestres (Gitelson et al. 2003). Nuestros resultados muestran una notable sensibilidad de la concentración de Chl-a a varias combinaciones de reflectancia multibanda, subrayando la alta capacidad de respuesta de este índice. Resultados similares se han observado en otros estudios de calidad del agua, en los que se han distinguido índices espectrales como el NDVI y el GNDVI, tal y como se recoge en trabajos anteriores (por ejemplo, Guimarães et al., 2017; Choo et al., 2018; y Kim et al., 2021). El GCI mostró el valor R^2 más alto de -0,88, convirtiéndolo en la mejor elección para el modelo de estimación de Chl-a en nuestro lago de estudio. La robustez del modelo se evaluó mediante el método bootstrapping, confirmando la significación de la correlación. Al comparar nuestros resultados con trabajos anteriores, un estudio notable que muestra una relación entre las bandas verde e infrarroja cercana y los valores de Chl-a in-situ es la investigación realizada por Yang et al. (2017). En su investigación, revelaron una correlación sustancial, con el índice de relación espectral B5 (infrarrojo cercano) / B3 (verde)

derivado del sensor OLI mostrando la asociación más fuerte con los niveles de clorofila-a in-situ ($R^2 = 0,73$).

El análisis de los parámetros de turbidez mostró que el índice espectral Rojo + NIR alcanzó el valor R^2 más alto, llegando a 0,79. Sin embargo, un elevado MAPE del 54,89% reveló las debilidades del modelo, lo que indica una falta de robustez. Los datos también mostraron variaciones estacionales, lo que pone de relieve la importancia de recoger datos de invierno (muestras de agua) para superar la limitación de este estudio. Así pues, para tener en cuenta el factor de estacionalidad de forma exhaustiva, es aconsejable incorporar datos de varias estaciones para el entrenamiento del modelo.

iii) Evaluación de la variabilidad espaciotemporal

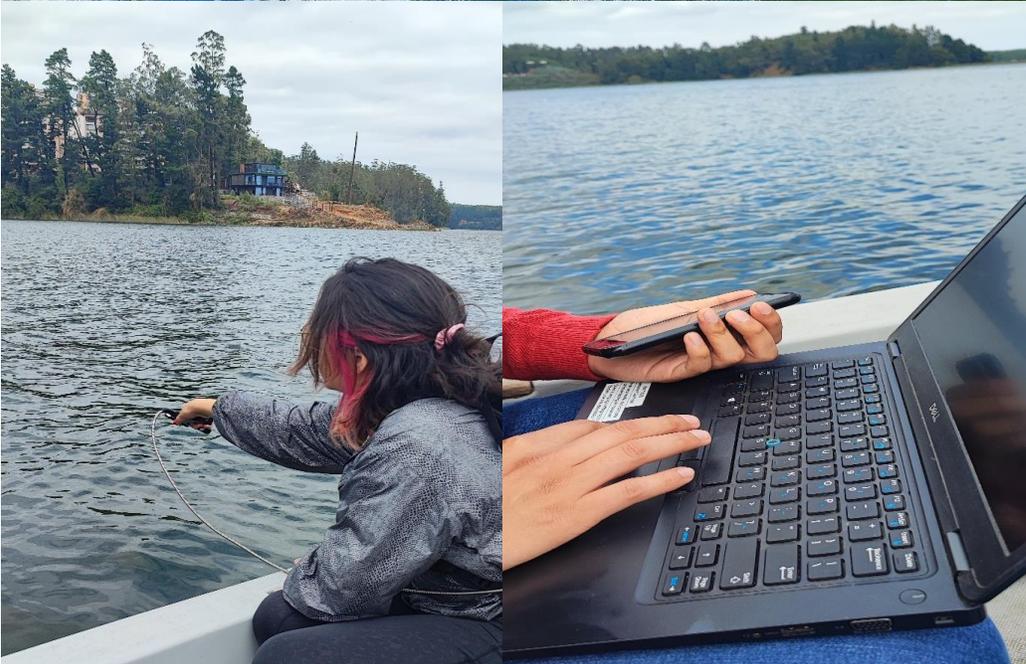
Nuestros resultados muestran claramente un patrón espacial que varía de valores de Chl-a más altos en la zona norte en comparación con la zona sur. Estos resultados están de acuerdo con la investigación de Pedrero-Guarda et al., (2021), que identificaron variaciones espaciales de temperatura en Laguna Grande, posiblemente atribuidas a un efecto de isla de calor (Anexo 3). Este efecto provoca diferencias de temperatura, con temperaturas más altas cerca de las zonas urbanas (parte norte) y temperaturas más bajas en las regiones con vegetación. Dado que los niveles de clorofila-a se ven afectados por factores como los nutrientes, el fósforo, el pH, el flujo de agua y la temperatura, es plausible que este gradiente de temperatura contribuya a niveles más altos de clorofila-a en la parte norte de la laguna. Un aspecto positivo de nuestro análisis surge al evaluar los valores de Chl-a estimados a partir de imágenes OLI entre 2014 y 2022. En general, se observa una disminución de las concentraciones de clorofila-a en todo el lago, lo que puede atribuirse a las recientes normativas locales destinadas a reducir las actividades que provocan la contaminación del lago. Sin embargo, será necesario evaluar una serie temporal a escala mensual para determinar si este descenso ha sido constante y se

mantiene.

Este estudio marca el primer paso hacia el desarrollo de una plataforma web que proporcionará acceso a datos de calidad del agua derivados de señales de satélite, como Landsat-8 OLI, para los principales lagos de Chile. En nuestro análisis en curso en la Laguna Grande, esperamos mejorar nuestros modelos de estimación espectral incorporando tecnología hiperespectral aerotransportada avanzada utilizando las cámaras HySpex VNIR-1800 de NEO y recopilando datos in-situ con otros parámetros de calidad del agua. Los resultados de este estudio fomentarán la utilización de datos de observación de la Tierra para vigilar la calidad de las aguas continentales, lo que facilitará la gestión sostenible de los recursos hídricos.

7. ANEXOS

Anexo 1. Registros salidas de campo



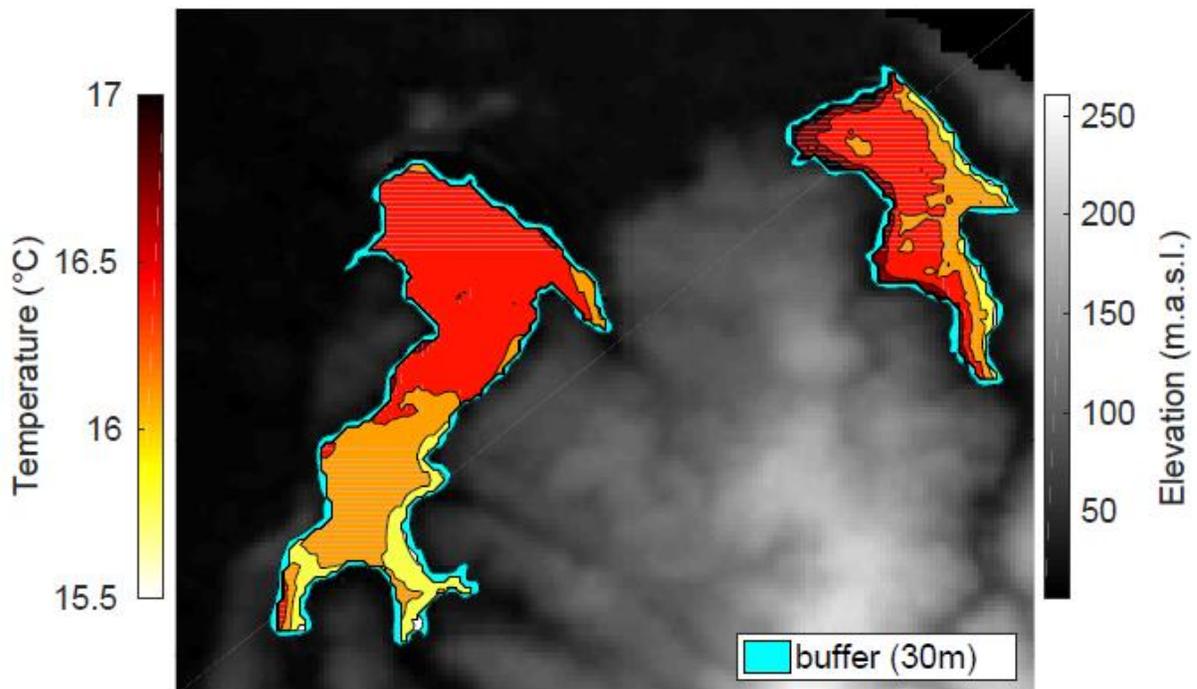
Anexo 2. Métricas estadísticas utilizadas para medir la efectividad de los modelos bio ópticos elegidos utilizando Acolite.

Parameter	Indices/Band combinations	MAE	MSE	RMSE	MAPE	R ²
Chlorophyll-a	Green Chlorophyll index (GCI)	0.35	0.20	0.45	7.56%	0.88
Turbidity	Red + Near Infrared	1.15	2.11	1.45	54.89%	0.79

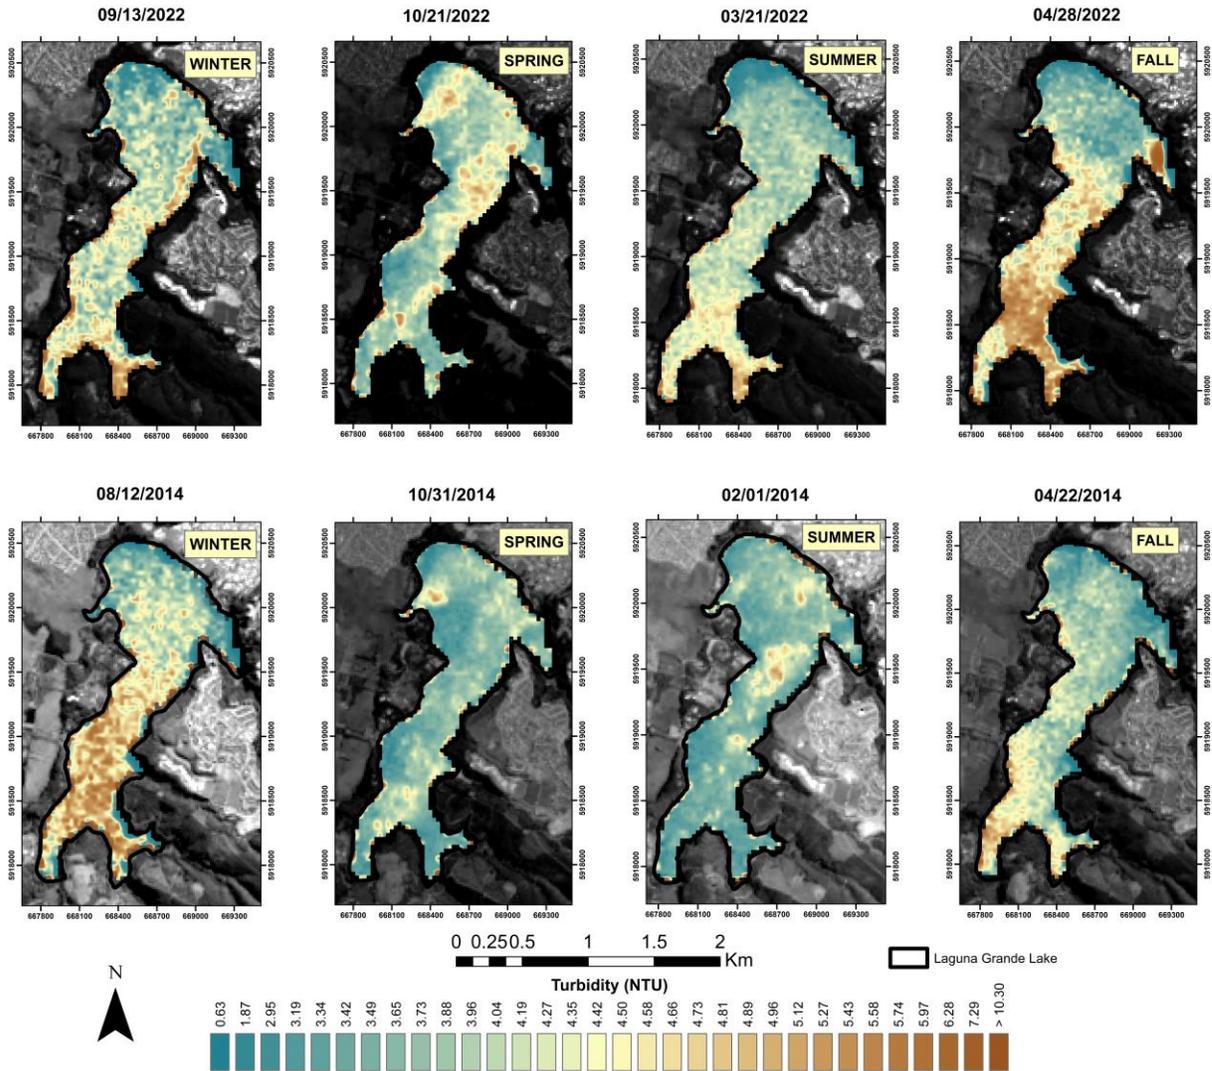
Anexo 2.1. Resultados estadísticos del segundo y tercer mejor método de corrección atmosférica para turbidez

AC processor	Indices/Band combinations	MAE	MSE	RMSE	MAPE	R ²
iCOR	Red + Near Infrared	1.14	2.05	1.43	59.32%	0.80
C2RCC	Red + Near Infrared	1.26	3.34	1.83	68.43%	0.67

Anexo 3. Figura extraída del trabajo de Pedreros-Guarda (2021) en la cual se muestra la climatología media anual de la Laguna Grande de San Pedro



Anexo 4. Mapas de distribución de turbidez para el Lago Laguna Grande



8. BIBLIOGRAFÍA

Abbas, MR., Rasib, AWB., Ahmad, BB., Musa, TAB., Abbas, TR., & Dutsenwai, HS. (2019). Landsat data to estimate a model of water quality parameters in Tigris and Euphrates Rivers - Iraq. *International Journal of Advanced and Applied Sciences*, 6(5), 50-58. <https://doi.org/10.21833/ijaas.2019.05.009>

Abdelal, Q., Assaf, M. N., Al-Rawabdeh, A., Arabasi, S., & Rawashdeh, N. A. (2022). Assessment of Sentinel-2 and Landsat-8 OLI for Small-Scale Inland Water Quality Modeling and Monitoring Based on Handheld Hyperspectral Ground Truthing. *Journal of Sensors*, 2022, 4643924. doi:10.1155/2022/4643924

Arar, E.J.; Collins, G.B. (1997) Method 445.0: In vitro determination of chlorophyll a and pheophytin a in marine and freshwater algae by fluorescence; United States Environmental Protection Agency, Washington, DC.

Asim, M.; Matsuoka, A.; Ellingsen, P.G.; Brekke, C.; Eltoft, T.; Blix, K. (2022). A new spectral harmonization algorithm for Landsat-8 and Sentinel-2 remote sensing reflectance products using machine learning: a case study for the Barents Sea (European Arctic). *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-19, doi:10.1109/TGRS.2022.3228393.

Bannari, A., Khurshid, K. S., Staenz, K., & Schwarz, J. W. (2007). A Comparison of Hyperspectral Chlorophyll Indices for Wheat Crop Chlorophyll Content Estimation Using Laboratory Reflectance Measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10), 3063-3074. doi:10.1109/TGRS.2007.897429

Baughman, C. A., Jones, B. M., Bartz, K. K., Young, D. B., & Zimmerman, C. E. (2015). Reconstructing Turbidity in a Glacially Influenced Lake Using the Landsat TM and ETM+ Surface Reflectance Climate Data Record Archive, Lake Clark, Alaska. *Remote Sensing*, 7(10), 13692-13710. Retrieved from <https://www.mdpi.com/2072-4292/7/10/13692>

Berk, A.; Anderson, G.P.; Acharya, P.K.; Bernstein, L.S.; Muratov, L.; Lee, J.; Fox, M.; Adler-Golden, S.M.; Chetwynd Jr, J.H.; Hoke, M.L. (2006). MODTRAN5: In *Proceedings of Algorithms and technologies for multispectral, hyperspectral, and ultraspectral imagery* xii; pp. 508-515.

Brockmann, C.; Doerffer, R.; Peters, M.; Kerstin, S.; Embacher, S.; Ruescas, A. (2016). 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 *Proceedings of Living Planet Symposium*; p. 54.

Carlson, R.E. (1977). A trophic state index for lakes 1. *Limnology and oceanography*, 22, 361-369.

Choo, Y.; Kang, G.; Kim, D.; Lee, S. (2018). A study on the evaluation of water-bloom using image processing. *Environmental Science and Pollution Research*, 25, 36775-36780, doi:<https://doi.org/10.1007/s11356-018-3578-6>.

Cooke, G. D., Welch, E. B., Peterson, S., & Nichols, S. A. (2016). *Restoration and management of lakes and reservoirs*: CRC press.

Cruces, F., Urrutia, R., Araneda, A., Torres, L., Cisternas, M., & Vyverman, w. (2001). Evolución trófica de Laguna Grande de San Pedro (VIII Región, Chile) durante el último siglo, mediante el análisis de registros sedimentarios. *Revista chilena de historia natural*, 74, 407-418. Retrieved from http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0716-078X2001000200015&nrm=iso

Cui, M., Sun, Y., Huang, C., & Li, M. (2022). Water Turbidity Retrieval Based on UAV Hyperspectral Remote Sensing. *Water*, 14(1), 128. Retrieved from <https://www.mdpi.com/2073-4441/14/1/128>

Dang, X., Du, J., Wang, C., Zhang, F., Wu, L., Liu, J., . . . Wang, J. (2023). A Hybrid Chlorophyll a Estimation Method for Oligotrophic and Mesotrophic Reservoirs Based on Optical Water Classification. *Remote Sensing*, 15(8), 2209. Retrieved from <https://www.mdpi.com/2072-4292/15/8/2209>

De Keukelaere, L.; Sterckx, S.; Adriaensen, S.; Knaeps, E.; Reusen, I.; Giardino, C.; Bresciani, M.; Hunter, P.; Neil, C.; Van der Zande, D. (2018). Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters. *European Journal of Remote Sensing*, 51, 525-542, doi:<https://doi.org/10.1080/22797254.2018.1457937>.

DGA, Dirección General de Aguas. (2014). Diagnóstico de la Condición Trófica de Cuerpos Lacustres Utilizando Nuevas Herramientas Tecnológicas. <https://snia.mop.gob.cl/sad/LGO5517.pdf>

Garg, V., Senthil Kumar, A., Aggarwal, S. P., Kumar, V., Dhote, P. R., Thakur, P. K.,

. . . Rastogi, G. (2017). Spectral similarity approach for mapping turbidity of an inland waterbody. *Journal of Hydrology*, 550, 527-537. doi:<https://doi.org/10.1016/j.jhydrol.2017.05.039>

Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289-298. doi:[https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

Gitelson, A. A., Gritz †, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271-282. doi:<https://doi.org/10.1078/0176-1617-00887>

Gitelson, A. A., Keydan, G. P., & Merzlyak, M. N. (2006). Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical research letters*, 33(11)

Guimarães, T.T.; Veronez, M.R.; Koste, E.C.; Gonzaga Jr, L.; Bordin, F.; Inocencio, L.C.; Larocca, A.P.C.; De Oliveira, M.Z.; Vitti, D.C.; Mauad, F.F. (2017). An alternative method of spatial autocorrelation for chlorophyll detection in water bodies using remote sensing. *Sustainability*, 9, 416.

Ha, N. T. T., Thao, N. T. P., Koike, K., & Nhuan, M. T. (2017). Selecting the Best Band Ratio to Estimate Chlorophyll-a Concentration in a Tropical Freshwater Lake Using Sentinel 2A Images from a Case Study of Lake Ba Be (Northern Vietnam). *ISPRS International Journal of Geo-Information*, 6(9), 290. Retrieved from <https://www.mdpi.com/2220-9964/6/9/290>

Harmel, T., Chami, M., Tormos, T., Reynaud, N., & Danis, P.-A. (2018). Sunglint correction of the Multi-Spectral Instrument (MSI)-SENTINEL-2 imagery over inland and sea waters from SWIR bands. *Remote Sensing of Environment*, 204, 308-321. doi:<https://doi.org/10.1016/j.rse.2017.10.022>

Huang, Z., Wu, X., Wang, H., Hwang, C., & He, X. (2023). Monitoring Inland Water Quantity Variations: A Comprehensive Analysis of Multi-Source Satellite Observation Technology Applications. *Remote Sensing*, 15(16), 3945. Retrieved from <https://www.mdpi.com/2072-4292/15/16/3945>

Kim, E.-J.; Nam, S.-H.; Koo, J.-W.; Hwang, T.-M. (2021). Hybrid approach of unmanned aerial vehicle and unmanned surface vehicle for assessment of chlorophyll-a imagery using spectral indices in stream, South Korea. *Water*, 13, 1930, doi:<https://doi.org/10.3390/w13141930>.

Kyryliuk, D.; Kratzer, S. (2019). Evaluation of Sentinel-3A OLCI products derived using the Case-2 Regional CoastColour processor over the Baltic Sea. *Sensors*, 19, 3609, doi:<https://www.mdpi.com/1424-8220/19/16/3609>.

Lei, F., Yu, Y., Zhang, D., Feng, L., Guo, J.-S., Zhang, Y., & Fang, F. (2020). Water remote sensing eutrophication inversion algorithm based on multilayer convolutional neural network. *Journal of Intelligent & Fuzzy Systems*, 39, 1-9. doi:10.3233/JIFS-189017

Lillo-Saavedra, M. F., & Gonzalo, C. (2008). Aplicación de la Metodología de Fusión

de Imágenes Multidirección-Multiresolución (MDMR) a la Estimación de la Turbidez en Lagos. Información tecnológica, 19, 137-146. Retrieved from http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-07642008000500015&nrm=iso

Millenium Ecosystem Assessment. (2005). Ecosystem and human well-being: synthesis. In: Island Press, Washington, DC.

Milton, E. (1987) Review article principles of field spectroscopy. Remote Sensing, 8, 1807-1827, doi:<https://doi.org/10.1080/01431168708954818>.

Mobley, C.D. (1999) Estimation of the remote-sensing reflectance from above-surface measurements. Applied optics, 38, 7442-7455.

Moses, W. J., Sterckx, S., Montes, M. J., De Keukelaere, L., & Knaeps, E. (2017). Chapter 3 - Atmospheric Correction for Inland Waters. In D. R. Mishra, I. Ogashawara, & A. A. Gitelson (Eds.), Bio-optical Modeling and Remote Sensing of Inland Waters (pp. 69-100): Elsevier

Normandin, C.; Lubac, B.; Sottolichio, A.; Frappart, F.; Ygorra, B.; Marieu, V. (2019). Analysis of suspended sediment variability in a large highly turbid estuary using a 5-year-long remotely sensed data archive at high resolution. Journal of Geophysical Research: Oceans, 124, 7661-7682, doi:<https://doi.org/10.1029/2019JC015417>.

Niroumand-Jadidi, M.; Bovolo, F.; Bresciani, M.; Gege, P.; Giardino, C. (2022) Water quality retrieval from landsat-9 (OLI-2) imagery and comparison to sentinel-2.

Remote Sensing, 14, 4596, doi:<https://doi.org/10.3390/rs14184596>.

Olmanson, L.G.; Brezonik, P.L.; Bauer, M.E. (2015) Remote sensing for regional lake water quality assessment: capabilities and limitations of current and upcoming satellite systems. *Advances in watershed science and assessment*, 111-140.

Pahlevan, N.; Smith, B.; Alikas, K.; Anstee, J.; Barbosa, C.; Binding, C.; Bresciani, M.; Cremella, B.; Giardino, C.; Gurlin, D. (2022). Simultaneous retrieval of selected optical water quality indicators from Landsat-8, Sentinel-2, and Sentinel-3. *Remote Sensing of Environment*, 270, 112860, doi:<https://doi.org/10.1016/j.rse.2021.112860>.

Parra, O., Valdovinos, C., Urrutia, R., Cisternas, M., Habit, E., & Mardones, M. (2003). Caracterización y tendencias tróficas de cinco lagos costeros de Chile Central. *Limnetica*, 22(1-2), 51-83.

Parra, O. (1989). La eutroficación de la Laguna Grande de San Pedro, Concepción, Chile: Un caso de estudio. *Ambiente y Desarrollo*, 5.

Pedrerros-Guarda, M., Abarca-del-Rio, R., Escalona, K., Garcia, I., & Parra, O. (2021). A Google Earth Engine Application to Retrieve Long-Term Surface Temperature for Small Lakes. Case: San Pedro Lagoons, Chile. *Remote Sensing*, 13, 4544. doi:10.3390/rs13224544

Peterson, K. T., Sagan, V., & Sloan, J. J. (2020). Deep learning-based water quality estimation and anomaly detection using Landsat-8/Sentinel-2 virtual constellation and cloud computing. *GIScience & Remote Sensing*, 57(4), 510-525.

doi:10.1080/15481603.2020.1738061

Quintana-Sotomayor, C., Lillo, M., Gonzalo-Martin, C., & Berrocal, J. (2012). Metodología para estimación de la turbidez de un lago mediante la clasificación orientada a objetos de imágenes multiespectrales. *Tecnología y Ciencias del Agua*, 3, 143-150.

Raynolds, M. K., Comiso, J. C., Walker, D. A., & Verbyla, D. (2008). Relationship between satellite-derived land surface temperatures, arctic vegetation types, and NDVI. *Remote Sensing of Environment*, 112(4), 1884-1894. doi:<https://doi.org/10.1016/j.rse.2007.09.008>

Rodríguez-López, L., Duran-Llacer, I., Bravo Alvarez, L., Lami, A., & Urrutia, R. (2023). Recovery of Water Quality and Detection of Algal Blooms in Lake Villarrica through Landsat Satellite Images and Monitoring Data. *Remote Sensing*, 15(7), 1929. Retrieved from <https://www.mdpi.com/2072-4292/15/7/1929>

Rodríguez-López, L., Duran-Llacer, I., González-Rodríguez, L., Abarca-del-Rio, R., Cárdenas, R., Parra, O., . . . Urrutia, R. (2020). Spectral analysis using LANDSAT images to monitor the chlorophyll-a concentration in Lake Laja in Chile. *Ecological Informatics*, 60, 101183. doi:<https://doi.org/10.1016/j.ecoinf.2020.101183>

Rojas Jordán, A. (2018). Evaluación de los efectos del cambio de uso de suelo sobre las tasas de sedimentación en Laguna Grande de San Pedro de la Paz (Chile) durante los últimos 30 años. Universidad de Concepción.

Schaeffer, B.A.; Schaeffer, K.G.; Keith, D.; Lunetta, R.S.; Conmy, R.; Gould, R.W. (2013) Barriers to adopting satellite remote sensing for water quality management. *International Journal of Remote Sensing*, 34, 7534-7544, doi:<https://doi.org/10.1080/01431161.2013.823524>.

Schiller, H.; Doerffer, R. (1999). Neural network for emulation of an inverse model operational derivation of Case II water properties from MERIS data. *International journal of remote sensing*, 20, 1735-1746, doi:<https://doi.org/10.1080/014311699212443>.

Silvoso, J.; Izaguirre, I.; Allende, L. (2011). Picoplankton structure in clear and turbid eutrophic shallow lakes: a seasonal study. *Limnologica*, 41, 181-190, doi:<https://doi.org/10.1016/j.limno.2010.10.001>.

Smith, B.; Pahlevan, N.; Schalles, J.; Ruberg, S.; Errera, R.; Ma, R.; Giardino, C.; Bresciani, M.; Barbosa, C.; Moore, T. (2021). A chlorophyll-a algorithm for Landsat-8 based on mixture density networks. *Frontiers in Remote Sensing*, 1, 623678, doi:<https://doi.org/10.3389/frsen.2020.623678>.

Sòria-Perpinyà, X., Vicente, E., Urrego, P., Pereira-Sandoval, M., Ruiz-Verdu, A., Delegido, J., . . . Moreno, J. (2020). Remote sensing of cyanobacterial blooms in a hypertrophic lagoon (Albufera of València, Eastern Iberian Peninsula) using multitemporal Sentinel-2 images. *Science of The Total Environment*, 698, 134305. doi:[10.1016/j.scitotenv.2019.134305](https://doi.org/10.1016/j.scitotenv.2019.134305)

Soriano-González, J., Urrego, E. P., Sòria-Perpinyà, X., Angelats, E., Alcaraz, C., Delegido, J., . . . Moreno, J. (2022). Towards the Combination of C2RCC Processors

for Improving Water Quality Retrieval in Inland and Coastal Areas. *Remote Sensing*, 14(5), 1124. Retrieved from <https://www.mdpi.com/2072-4292/14/5/1124>

Steissberg, T., Schladow, S., & Hook, S. (2010). Monitoring past, present, and future water quality using remote sensing. Tahoe environmental research center and jet propulsion laboratory (NASA).

Urrutia, R. (2021). Estudio del estado trófico de los cuerpos de agua existentes en San Pedro de la Paz. https://sanpedrodelapaz.cl/wp-content/uploads/2023/01/PPT-SEMINARIO_Final_2.pdf

USGS. (2023). Landsat 8-9 Collection 2 (C2) Level 2 Science Product (L2SP) Guide. https://d9wret.s3.uswest2.amazonaws.com/assets/palladium/production/s3fspublic/media/files/LSDS1619_Landsat8-9-Collection2-Level2-Science-Product-Guide-v5.pdf

van Rees, C. B., Waylen, K. A., Schmidt-Kloiber, A., Thackeray, S. J., Kalinkat, G., Martens, K., . . . Jähnig, S. C. (2021). Safeguarding freshwater life beyond 2020: Recommendations for the new global biodiversity framework from the European experience. *Conservation Letters*, 14(1), e12771. doi:<https://doi.org/10.1111/conl.12771>

Vanhellemont, Q. (2019a). Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives. *Remote Sensing of Environment*, 225, 175-192. doi:<https://doi.org/10.1016/j.rse.2019.03.010>

Vanhellemont, Q. (2019b). Daily metre-scale mapping of water turbidity using CubeSat imagery. *Optics Express*, 27(20), A1372-A1399. doi:10.1364/OE.27.0A1372

Vanhellemont, Q. (2020). Sensitivity analysis of the dark spectrum fitting atmospheric correction for metre- and decametre-scale satellite imagery using autonomous hyperspectral radiometry. *Opt Express*, 28(20), 29948-29965. doi:10.1364/oe.397456

Vanhellemont, Q., & Ruddick, K. (2018). Atmospheric correction of metre-scale optical satellite data for inland and coastal water applications. *Remote Sensing of Environment*, 216, 586-597. doi:<https://doi.org/10.1016/j.rse.2018.07.015>

Vanhellemont, Q., & Ruddick, K. (2021). Atmospheric correction of Sentinel-3/OLCI data for mapping of suspended particulate matter and chlorophyll-a concentration in Belgian turbid coastal waters. *Remote Sensing of Environment*, 256, 112284. doi:<https://doi.org/10.1016/j.rse.2021.112284>

Wolters, E., Toté, C., Sterckx, S., Adriaensen, S., Henocq, C., Bruniquel, J., . . . Dransfeld, S. (2021). iCOR Atmospheric Correction on Sentinel-3/OLCI over Land: Intercomparison with AERONET, RadCalNet, and SYN Level-2. *Remote Sensing*, 13(4), 654. Retrieved from <https://www.mdpi.com/2072-4292/13/4/654>

Yang, Z.; Reiter, M.; Munyei, N. (2017). Estimation of chlorophyll-a concentrations in diverse water bodies using ratio-based NIR/Red indices. *Remote Sensing Applications: Society and Environment*, 6, 52-58, doi:<https://doi.org/10.1016/j.rsase.2017.04.004>.

Yépez, S., Laraque, A., Martinez, J., De Sá Rodriguez, J., Carrera, J., Castellanos, B., . . . Lopez, J. (2018). Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River (Venezuela). *Comptes Rendus Geosciences*, 350. doi:10.1016/j.crte.2017.08.004

Zhang, H., Xue, B., Wang, G., Zhang, X., & Zhang, Q. (2022). Deep Learning-Based Water Quality Retrieval in an Impounded Lake Using Landsat 8 Imagery: An Application in Dongping Lake. *Remote Sensing*, 14(18), 4505. Retrieved from <https://www.mdpi.com/2072-4292/14/18/4505>