



Universidad de Concepción
Facultad de Ciencias Ambientales
Ingeniería Ambiental



EVALUACIÓN DEL ESTADO TRÓFICO DEL LAGO LLANQUIHUE A TRAVÉS DE TÉCNICAS DE TELEDETECCIÓN

Habilitación presentada para optar al título de
Ingeniero Ambiental

Por: Alvaro Tripayán Villagra

Profesor Guía: Mauricio Aguayo Arias

Concepción, Chile 2024



“EVALUACIÓN DEL ESTADO TRÓFICO DEL LAGO LLANQUIHUE A TRAVÉS DE TÉCNICAS DE TELEDETECCIÓN”

Profesor Guía: Dr. Mauricio Aguayo Arias

Profesor Comisión: Dra. Alberto Araneda Castillo

Profesor Comisión: Dr. Roberto Urrutia Pérez

CONCEPTO: APROBADO CON DISTINCIÓN MÁXIMA

Conceptos que se indica en el Título

- ✓ Aprobado por Unanimidad : (En Escala de 4,0 a 4,9)
- ✓ Aprobado con Distinción (En Escala de 5,0 a 5,6)
- ✓ Aprobado con Distinción Máxima (En Escala de 5,7 a 7,0)

Concepción, abril 2024

AGRADECIMIENTOS

A mi madre y a mi padre quienes siempre han estado presente a pesar de la distancia. Por su confianza, guía y apoyo en mis decisiones a través de los años.

A mis abuelos y abuelas que a través de su cariño, experiencias e historias me han inculcado valores y una perspectiva más amplia de la vida.

A los amigos que hice en el camino, por los momentos que compartimos, por las juntas que desahogaban y las salidas a explorar.

A los docentes que me apoyaron en esta ultima etapa, en especial a el profesor Mauricio Aguayo, por su tiempo, paciencia y ayuda.

Índice

Índice de Tablas.....	vi
Índice de Figuras	vii
RESUMEN.....	viii
INTRODUCCIÓN	1
1.- Pregunta de Investigación	3
2.- Objetivos.....	3
2.1.-Objetivo General	3
2.2.-Objetivos específicos	3
3.-Marco Teórico.....	4
3.1.- Estado de los lagos	4
3.2.- Situación Chile	10
3.3.- Estado trófico de lagos en Chile.....	12
3.4.- Teledetección.....	14
3.4.1.- Tipos de Sensores.....	19
3.4.2.- Resolución del sistema sensor	20
3.4.3.- Tipos de modelos en teledetección	21
3.5.- Teledetección y cuerpos de agua	22
3.6.- Sentinel-2.....	26
3.7.- Modelos Lineales	28
4.- Metodología.....	30
4.1.- Área de estudio	30
4.2.- Google Earth Engine	34
4.3.- Elaboración de la base de datos	35
4.4.- Análisis preliminar de los datos	38
4.5.- Regresión Lineal múltiple	38
4.6.- Relación entre variables.....	39
4.7.- Selección de Predictores.....	40
4.8.- Bondad de Ajuste del Modelo	40
4.9.- Diagnóstico del Modelo de Regresión.....	42

4.10.- Ajuste del Modelo.....	43
4.11.- Colinealidad	44
5.- Resultados.....	45
5.1.- Análisis Preliminar de los Datos	47
5.2.- Ajuste de Modelos	51
5.2.1.- Modelo 1	51
5.2.2.- Modelo 2.....	59
6.-Discusión	64
7.- Conclusiones	67
8.- Bibliografía.....	69
8.- Anexos.....	73

Índice de Tablas

Tabla N°1: Estaciones de Monitoreo EULA.....	32
Tabla N°2: Resumen de la Base de Datos generada	46
Tabla N°3: Selección de predictores Modelo 1	52
Tabla N°4: Coeficientes del Modelo 1	52
Tabla N°5: Medidas de Bondad de Ajuste Modelo 1	52
Tabla N°6: Factor de Inflación de la varianza Modelo 1	56
Tabla N°7: Coeficientes del Modelo 2	59
Tabla N°8: Medidas de Bondad de ajuste Modelo 2.....	59
Tabla N°9: Factor de inflación de varianza Modelo 2	62
Tabla N°10: Bondad de ajuste de los Modelos.....	66
Tabla N°11: Ecuaciones de Regresión	66

Índice de Figuras

Figura N°1: Clasificación de lagos por Ecorregiones	11
Figura N°2: Estado trófico de los lagos de Chile. Clasificación basada en mediciones históricas promedio de clorofila-a, y en la clasificación propuesta por Smith 1999.....	13
Fuente: (DGA, 2014).....	13
Figura N°3: Espectro electromagnético.....	17
Figura N°4: Firmas espectrales típicas para distintas cubiertas.....	19
Figura N°5: Dirección especular (izquierda), reflector difuso ideal (derecha) ...	23
Figura N°6: Configuración Orbital de los satélites gemelos Sentinel-2 (European Space Agency).....	26
Fuente: Elaboración propia.....	32
Figura N°7: Ubicación área de estudio y estaciones de monitoreo Elaboración Propia	33
.....	37
Figura N°8: Filtro de información satelital para la elaboración de la base de datos	37
Figura N°9: Grafico de caja de datos de concentración de clorofila-a.....	47
Figura N°10: Distribución de las variables numéricas.....	48
Figura N°11: Matriz de correlación utilizando el coeficiente de Spearman	50
Figura N°13: Inspección Visual de los Residuos Modelo 1 Elaboración Propia a través de Spyder.....	54
Figura N°14: Predicción de la concentración de clorofila-a aplicando el Modelo 1 la imagen del 07/02/2021.....	58
Figura N°15: Predicción [Chl-a] para los periodos verano (superior) e invierno (inferior). Las concentraciones indicadas corresponden el intervalo de valores del muestreo in-situ para la fecha correspondiente.	58
Figura N°16: Inspección Visual de los Residuos Modelo 2	61
Figura N°17: Mapa de predicción de Concentración de clorofila aplicando el modelo 2 a la imagen Sentinel del 07/02/2021	63
Figura N°18: Predicción [Chl-a] para los periodos verano (superior) e invierno (inferior). Las concentraciones indicadas corresponden el intervalo de valores del muestreo in-situ para la fecha correspondiente	63

RESUMEN

Los cuerpos de agua continentales son una fuente importante para el consumo humano y el desarrollo de actividades económicas. Además, son fundamentales para la conservación de especies de flora y fauna, por lo que monitorear su calidad y conocer su estado es esencial para la toma de decisiones en la gestión de los recursos hídricos. Sin embargo, los métodos tradicionales de monitoreo presentan limitaciones en cuanto a cobertura espacial, temporal y recursos económicos, lo que dificulta obtener un conocimiento representativo de los cuerpos de agua. El uso de información satelital y técnicas de teledetección ha demostrado ser una herramienta potencial para complementar y ampliar la información disponible sobre los parámetros de calidad del agua en el mundo.

En el presente trabajo, se buscó evaluar el estado trófico del lago Llanquihue mediante herramientas de teledetección, analizando la correlación entre los datos satelitales y la concentración de clorofila-a obtenida de muestras in situ. Para ello, se utilizaron imágenes satelitales del sensor multiespectral (MSI) de los satélites gemelos Sentinel-2. Se seleccionaron imágenes cercanas a las fechas de muestreo para analizar y evaluar las correlaciones entre los valores de las bandas espectrales y los datos disponibles de concentración de clorofila-a. Posteriormente, se exploraron los datos obtenidos mediante ajustes en modelos de regresión lineal múltiple con mínimos cuadrados ordinarios.

Los resultados mostraron correlaciones estadísticamente significativas entre cinco bandas espectrales del sensor MSI de Sentinel-2 y los datos de concentración de clorofila-a medidos en la superficie del lago. Además, se lograron ajustar modelos de regresión lineal múltiple que cumplen con los supuestos de este tipo de análisis, lo que permitió ampliar la información disponible y visualizar la distribución estimada de clorofila-a. Según las predicciones obtenidas, el lago Llanquihue mantiene un estado de oligotrofia en su superficie para la serie temporal seleccionada.

INTRODUCCIÓN

Los cuerpos de agua superficiales son esenciales para sustentar la vida, cubrir las necesidades humanas y preservar la biodiversidad en ecosistemas como ríos, lagos y humedales, proporcionando hábitats para diversas especies de flora y fauna (Barraza-moraga et al., 2022). Actualmente, se reconoce que los lagos desempeñan un rol fundamental en el ciclo del carbono y como reguladores del clima. Además, actúan como buenos indicadores de cambio ambiental debido a su sensibilidad y rápida respuesta a modificaciones en su cuenca y en la atmósfera (Huovinen et al., 2019). Sin embargo, los lagos enfrentan múltiples presiones ambientales, incluyendo el enriquecimiento de nutrientes, contaminación, cambio climático, acidificación y especies invasoras (Palmer et al., 2015).

Dada la importancia de estos ecosistemas y las crecientes presiones que enfrentan, es urgente contar con métodos precisos para evaluar y monitorear su estado y los procesos que en ellos ocurren. Los monitoreos in situ, aunque fundamentales, presentan limitaciones en cuanto a cobertura espacial y temporal, además de ser poco representativos en algunos casos, o incluso inexistentes en ciertas regiones (Palmer et al., 2015).

El acceso gratuito a datos satelitales en los últimos años ha permitido el uso de la teledetección como una herramienta complementaria para la vigilancia ambiental, mejorando la observación espacial y temporal de los cuerpos de agua (Huovinen et al., 2019). Estas tecnologías facilitan la estimación remota de indicadores de calidad del agua, como clorofila-a sólidos suspendidos, turbidez y otros parámetros relacionados (Toming et al., 2016).

En este contexto, el presente estudio examina la disponibilidad de datos del sensor Sentinel-2 para el lago Llanquihue y evalúa la correlación entre los valores de sus bandas espectrales y la concentración de clorofila-a, con el fin de

desarrollar un modelo que amplíe la información sobre la calidad del agua en el lago. Para esto, se estableció como objetivo general evaluar la correlación entre los datos del monitoreo del lago Llanquihue y los datos obtenidos mediante técnicas de teledetección.

1.- Pregunta de Investigación

¿Existe una correlación significativa entre los datos del sensor MSI de Sentinel-2 y los datos del monitoreo del Lago Llanquihue que permita determinar y clasificar su estado trófico?

2.- Objetivos

2.1.-Objetivo General

Evaluar las correlaciones entre los datos de muestreo del Lago Llanquihue y los datos del sensor MSI de Sentinel-2 en el periodo del muestreo 2020-2021

2.2.-Objetivos específicos

Objetivo específico 1

Analizar las relaciones entre la concentración de clorofila-a y las bandas espectrales del sensor MSI de Sentinel-2

Objetivo específico 2

Determinar la viabilidad de generar un modelo de regresión lineal múltiple utilizando datos del sensor MSI para estimar la concentración de clorofila-a

3.-Marco Teórico

3.1.- Estado de los lagos

Los lagos se originan principalmente por la obstrucción del drenaje superficial debido particularmente a procesos morfogenéticos, estos reciben aportes sólidos y líquidos provenientes de su cuenca de drenaje, mediante escorrentía superficial y subterránea, razón por la que las características de la calidad del agua y de las comunidades biológicas allí presentes, reflejan los efectos acumulados de todos los aportes (DGA, 2022).

Los lagos proporcionan recursos hídricos para diversos usos humanos y funciones ecológicas, además dan lugar a el hábitat de especies y servicios ecosistémicos importantes y diversos. Sin embargo, son ecosistemas altamente vulnerables y se han visto amenazados por efectos sinérgicos de múltiples presiones ambientales, como el enriquecimiento de nutrientes orgánicos e inorgánicos, el cambio climático, acidificación, y la propagación de especies invasoras (Palmer,S.C. et al. 2015).

Uno de los aspectos que más ha alterado y amenaza a estos cuerpos de agua es la eutroficación, proceso de contaminación que incide directamente en el deterioro continuo de los ecosistemas acuáticos y que es producido por acciones humanas y/o procesos naturales (Moreno et al. 2010).

La acumulación de nutrientes, el aumento de la productividad biológica y la deposición de sedimentos provenientes de la cuenca de drenaje son factores que causan la eutroficación, proceso que representa el envejecimiento natural de los lagos. Este proceso es lento en condiciones naturales, pero puede verse acelerado debido a causas antrópicas como el cambio en el uso del suelo, el incremento de la erosión, la descarga de aguas residuales y el uso excesivo de fertilizantes, entre otros, lo que altera la calidad del agua (DGA,2022).

Este proceso es de interés debido a que la degradación de la calidad del agua, pérdida de diversidad, exceso de sedimentos, y un aumento en la alteración de las cadenas tróficas en los cuerpos de agua son de gran preocupación en un escenario donde el suministro de agua presenta una gran demanda (Abid A. et.al, 2011). Las causas de la eutroficación pueden ser clasificadas en naturales y antrópicas.

Causas Naturales

Entre las causas naturales se encuentra la escorrentía generada por precipitaciones, que contribuye al aporte natural de sedimentos y nutrientes a los cuerpos de agua. Este proceso puede desencadenar un aumento en la turbidez y, en consecuencia, un incremento en la productividad biológica. Otro factor natural es la descomposición de materia orgánica, realizada tanto por bacterias aerobias como anaerobias, que libera nutrientes esenciales como nitrógeno y fósforo al agua, promoviendo el crecimiento de algas y plantas acuáticas (Pozo, 2008).

Causas Antropogénicas

Entre las causas de origen antrópico que contribuyen a la eutroficación se encuentran los vertidos y la infiltración de aguas residuales domésticas, agrícolas e industriales, las cuales contienen altos niveles de nitrógeno y fosforo. Estos nutrientes son los principales responsables del enriquecimiento de nutrientes en los cuerpos de agua. Además, la presión del desarrollo urbano, la construcción de viviendas e infraestructura en las cuencas de los lagos, y el crecimiento de asentamientos poblacionales también juegan un papel importante. El uso del suelo para fines urbanos, recreacionales y habitacionales, junto con la expansión de redes de urbanización, el drenaje de aguas subterráneas y los sistemas de alcantarillado de aguas servidas y pluviales, agravan el problema (Pozo, 2008).

Estas actividades se consideran la principal amenaza para la calidad de las aguas continentales en gran parte del mundo, ya que generan cambios profundos en los ecosistemas acuáticos y afectan tanto el ambiente natural como los usos humanos de estos recursos (Ansari et al, 2010).

De las causas mencionadas, los contaminantes de origen antrópico más importantes pueden agruparse en dos tipos principales.

- Aguas residuales domésticas, que contienen gran cantidad de materia orgánica y detergentes que son descargan directamente en los cuerpos de agua.
- Entrada de fertilizantes, principalmente en base a nitrógeno y fosforo, que provienen de faenas agrícolas y que llegan a los lagos a través de escorrentías superficiales o infiltraciones subterráneas (Pozo, 2008).

Para estudiar y conocer el estado trófico de los ecosistemas acuáticos se establecen redes de vigilancia que realizan muestreos y observaciones de variables de interés, estas variables se pueden dividir en dos grandes categorías:

Variables Abióticas

- **Temperatura**

La temperatura del agua es un parámetro ecológico clave para comprender los procesos en los ecosistemas acuáticos, ya que cada organismo y actividad biológica tiene rangos de temperatura óptimos. La temperatura de un lago depende del flujo y la distribución de la radiación solar. En los lagos, este fenómeno genera una estratificación en función de la radiación y la profundidad, lo que crea un gradiente de temperatura y densidad desde la superficie hasta el fondo (Sobrino, 2014).

Como resultado de ese flujo de calor, se forman tres capas en la columna de agua:

- Epilimnion: Capa superficial, de mayor temperatura y menor densidad, caracterizada por la mezcla y circulación del agua.
 - Metalimnion: Zona de transición con un marcado gradiente térmico, donde se sitúa la termoclina (capa donde ocurre un rápido descenso de la temperatura).
 - Hipolimnion: Capa inferior, con agua más fría, densa y homogénea (Sobrino, 2014).
- **Oxígeno Disuelto**

El oxígeno disuelto en el agua proviene principalmente de la fotosíntesis realizada por organismos con clorofila en las capas superficiales, donde la concentración es mayor debido a la incidencia de la luz. En las capas más profundas, el oxígeno disuelto disminuye debido a la oxidación de la materia orgánica (Pozo, 2008). Su concentración está directamente influenciada por la temperatura del agua, la radiación solar y la profundidad del lago (Pozo, 2008).
 - **Fósforo total**

El fósforo total es la suma de todas las formas de fósforo, tanto orgánicas como inorgánicas. Este nutriente ingresa a los lagos a través de vertidos industriales, aguas residuales domésticas y escorrentía superficial o subterránea de las cuencas. El incremento de fósforo en un lago puede provocar un aumento en el estado trófico, especialmente si el fósforo es un reactivo limitante (Pozo, 2008).
 - **Nitrógeno total**

El nitrógeno es un componente esencial de los aminoácidos y proteínas de los organismos. Puede ingresar a los lagos a través de la precipitación, fijación del nitrógeno atmosférico y la escorrentía superficial o subterránea. El nitrógeno total incluye diversas formas como el nitrógeno orgánico, nitrato (NO₃-), nitrito (NO₂-) y amonio (NH₄+), entre otras (Pozo, 2008).

- **Turbidez**

La turbidez es un indicador de la cantidad de sólidos suspendidos en el agua. Depende del tamaño, forma y propiedades refractivas del material particulado, lo que modifica la absorción y refracción de la luz. Se clasifica en sólidos suspendidos y materia disuelta (Sobrino, 2014).

- **Materia orgánica disuelta coloreada (CDOM)**

La materia orgánica disuelta coloreada (CDOM) es el sustrato principal para el crecimiento bacteriano en los sistemas acuáticos. Estas sustancias absorben la radiación en el espectro cercano al ultravioleta, afectando significativamente el color del agua (Sobrino, 2014).

Variables bióticas

- **Productividad primaria**

La clorofila-a es el principal pigmento fotosintético presente en las algas, y su concentración ([Chl-a]) es un parámetro clave para medir la productividad primaria en los ecosistemas acuáticos. Este pigmento está correlacionado con la biomasa total del fitoplancton y es un indicador del estado trófico de los lagos (Sobrino, 2014).

- **Concentración de materia orgánica e inorgánica**

El agua contiene sustancias disueltas y material particulado en suspensión, compuesto tanto por fracciones orgánicas vivas como muertas e inorgánicas. Este material, conocido como materia en suspensión total (TSM), regula la entrada de luz en la columna de agua y afecta la calidad del hábitat acuático (Sobrino, 2014).

Efectos de la eutrofización

Los principales efectos que desencadena el proceso de eutrofización son los siguientes:

- Aumento de la producción y biomasa de los productores primarios.
- Elevada mortandad de peces.
- Desoxigenación del agua.
- Producción de toxinas por parte de especies de algas.
- Aumento de gastos de operación de los sistemas públicos de abastecimiento de agua.
- Colmatación y obstrucción de canales de riego.
- Reducción del uso del agua para fines recreativos.
- Impedimentos a la navegación.
- Pérdidas económicas debido a la modificación de especies piscícolas.

En un ecosistema eutrófico, se observan dos procesos importantes: el aumento de la demanda de oxígeno para descomponer la materia orgánica y el incremento en la población de productores primarios. Debido a estos efectos, resulta fundamental intensificar la cobertura y el monitoreo de los cuerpos de agua dulce con el objetivo de desarrollar planes de gestión y manejo más eficientes.

Sin embargo, el monitoreo convencional in situ, implementado en la mayoría de los lagos, presenta limitaciones en cuanto a cobertura espacial, representatividad y frecuencia de muestreo, lo que dificulta la comprensión completa de los procesos ecológicos (Palmer, S.C et al., 2015).

En un ecosistema eutrófico ocurren dos procesos significativos; se requiere más oxígeno para descomponer la materia orgánica y aumenta la población de productores primarios.

Es debido a los efectos mencionados que es necesario aumentar la cobertura y el monitoreo en los cuerpos de agua dulce para poder desarrollar eficientes planes de gestión y manejo.

Sin embargo, el monitoreo convencional in situ implementado en la mayoría de los lagos es limitado en términos de cobertura espacial y representatividad, así como en términos de frecuencia (Palmer,S.C et al.,2015).

3.2.- Situación Chile

El control e investigación de parámetros lacustres a nivel nacional responde a las atribuciones, funciones y obligaciones de la Dirección General de Aguas (DGA) establecidas en el Art° 299 del código de aguas, en especial a lo referente con la investigación, medición del recurso, mantener operativas estaciones de calidad del agua y publicar la información a quien lo solicite (DGA, 2014).

Bajo la directriz de la DGA en la década de los 80 se dio inicio al monitoreo de la calidad del agua con la operación de la “red nacional mínima de control de lagos” que tiene como objetivo principal generar información pública y sistemática que caracterice la calidad de los lagos y lagunas del país, incluido su estado trófico (DGA, 2014).

A 2021 la red de monitoreo de lagos ha ejecutado este servicio y también ha sido externalizado a través de diferentes estudios. En total se han muestreado 166 estaciones de lagos distribuidas en 57 cuerpos lacustres a lo largo de Chile. La información generada a lo largo de los años es fundamental para la evaluación de la condición trófica y también se ha utilizado como antecedentes para la generación de Normas Secundarias de Calidad Ambiental (NSCA) como es el caso del lago Llanquihue y Villarrica los cuales cuentan con NSCA aprobadas mediante DS N°122/2010 y DS N°19/2013, respectivamente (DGA, 2021).

Debido a la heterogeneidad climática y geográfica que presenta Chile, los cuerpos lacustres presentan características representativas según su

localización, por esta razón con el objetivo de estudiar y clasificar estas características regionales los lagos han sido agrupadas en ecorregiones según el grado de similitud en cuanto a sus características ambientales (Figura N°1), como clima, vegetación, hidrología, latitud, altitud, usos, entre otros. Según lo defina el objetivo del estudio (DGA.,2014).

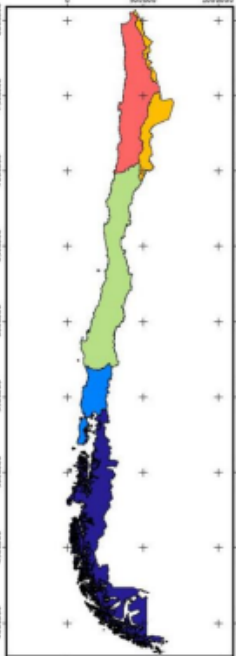
Mapa	Ecorregión	Tipos de Lagos por Ecorregión	Ejemplos de cuerpos de agua de la Ecorregión
 <p data-bbox="363 1465 544 1486">Ecorregiones para Chile</p> <ul data-bbox="363 1514 544 1696" style="list-style-type: none"> ■ Atacama ■ Altiplano ■ Mediterránea ■ Lagos Valdivianos ■ Patagonia 	<p>Altiplano Se extiende por el Altiplano y la Puna de Atacama comprendiendo las cuencas Altiplánicas (límite norte) y las cuencas endorreicas del Salar de Atacama-Vertiente del Pacífico (límite sur).</p>	Bofedales y Vegas	Chungará y Cotacotani
	<p>Atacama Se extiende desde cuenca de la Quebrada de la Concordia hasta las cuencas costeras entre los ríos Salado y Copiapó y la cuenca del río Salado</p>	Atacameños	Salares. Ríos Lluta y Loa.
	<p>Mediterránea Se extiende desde la cuenca del río Copiapó (límite norte) hasta la cuenca del río Imperial (límite sur)</p>	Andino	Laguna Negra, Embalse el Yeso, Laguna Laja, Maule, etc.
		De Valle	Aculeo, Embalse Rapel, Embalse La Paloma
		Costeros*	Vichuquén, Torca, Embalse Peñuelas, Lleulleu, Lanahue, etc
	<p>Lagos Valdivianos Se extiende desde la cuenca del Río Toltén hasta las cuencas e islas entre río Bueno y río Puelo, abarcando los lagos Villarrica por el norte, Llanquihue por el sur, e Isla de Chiloé.</p>	Araucanos	Villarrica, Calafquén, Ranco, Llanquihue, Puyehue, Rupanco, etc.
Costeros*		Budi	
De Chiloé		Cucao, Huillinco, Tarahuin, Popetán, Tepuhueico, etc.	
<p>Patagonia Se extiende desde la cuenca del río Puelo hasta las cuencas de las islas al sur del Canal Beagle.</p>	Patagónicos y Magallánicos	Yelcho, Bertrand, Cochrane, O'Higgins, General Carrera, etc.	

Figura N°1: Clasificación de lagos por Ecorregiones

Fuente: (DGA.,2014).

3.3.- Estado trófico de lagos en Chile

A cargo de la DGA en 2014 se analizó el estado trófico de los lagos de Chile a través del parámetro clorofila-a, utilizando la clasificación de *Smith*. Esta clasificación agrupa información de distintos periodos de tiempo, así como distinta cantidad de registros. Para poder determinar el estado trófico se obtuvieron promedios anuales basados en la mayor cantidad posible de mediciones. Los resultados mostraron que la mayoría de los lagos y embalses cuya condición trófica ha sido estudiada se concentran en la zona centro sur de Chile. Además, se distingue un gradiente latitudinal entre las zonas centro y sur del país (Figura N°2), donde varios de los lagos y embalses, desde cuarta a la octava región presentan una condición entre mesotrófica e hipertrófica, cambiando a oligotrófica hacia el sur. También se observa un gradiente altitudinal donde los lagos ubicados entre el valle central y la cordillera presentan una mejor condición trófica que los ubicados entre la costa y el valle central. Aunque esta clasificación agrupa información de diferentes periodos de tiempo y de diversos registros en los lagos, se obtuvieron promedios anuales basados en la mayor cantidad posible de mediciones, por lo que, de todas formas, el análisis realizado por la DGA constituye una aproximación general del estado trófico de los lagos y embalses a nivel nacional (DGA, 2014).

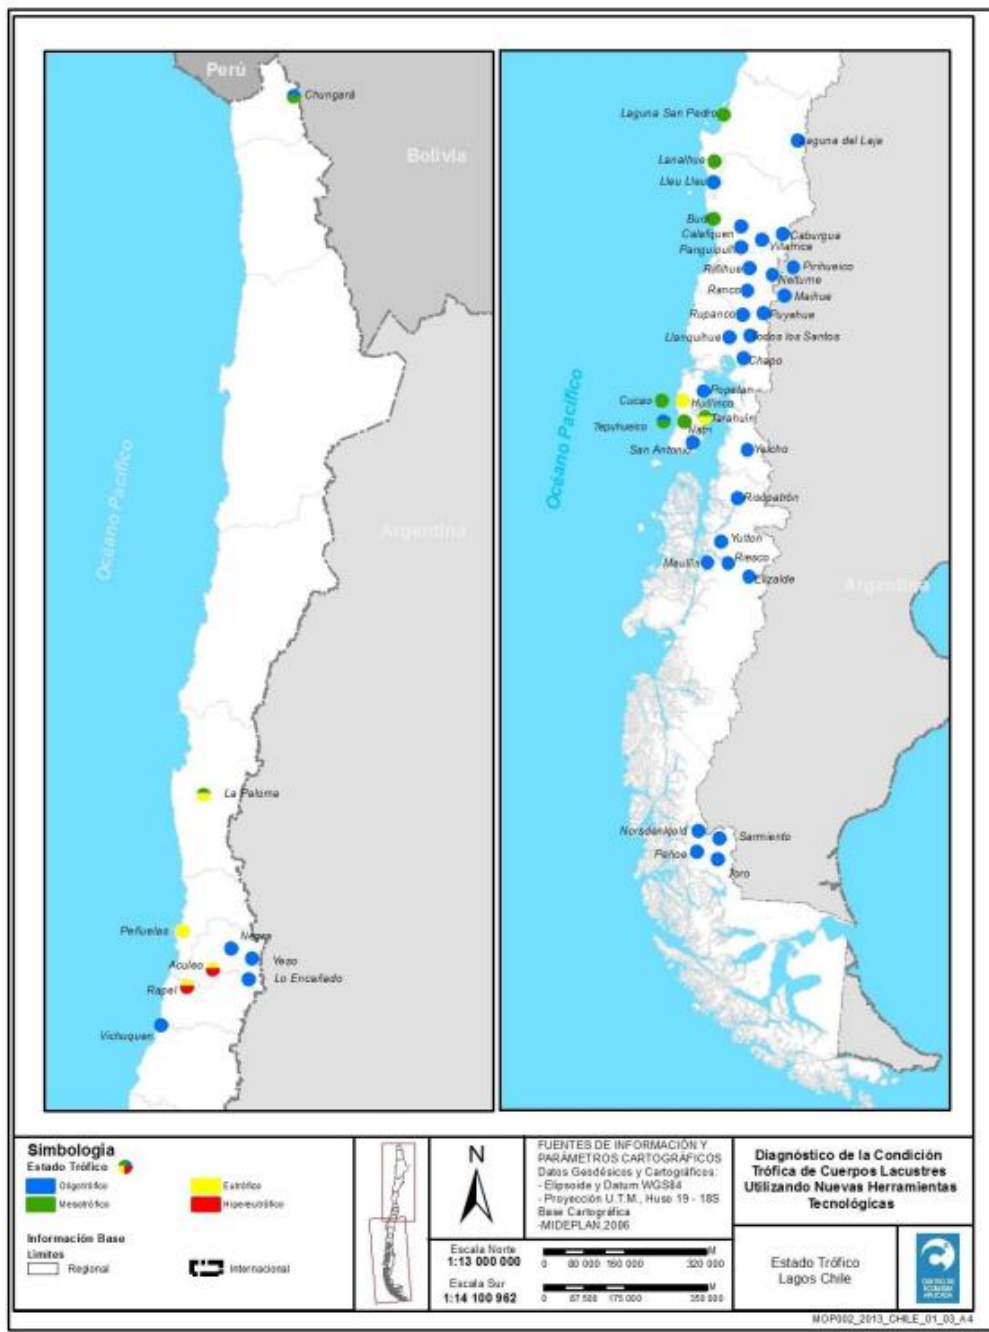


Figura N°2: Estado trófico de los lagos de Chile. Clasificación basada en mediciones históricas promedio de clorofila-a, y en la clasificación propuesta por Smith 1999.

Fuente: (DGA, 2014)

3.4.- Teledetección

Es fundamental aumentar la cobertura y el monitoreo de los cuerpos de agua dulce para desarrollar planes de gestión y manejo eficientes, debido a los efectos negativos que provoca la eutroficación. El monitoreo in situ convencional presenta limitaciones importantes en cuanto a la cobertura espacial, frecuencia de observación y representatividad, por lo que es necesario complementar el conocimiento disponible con nuevas metodologías. En este sentido, se han considerado el uso de técnicas de muestreo remoto y teledetección (DGA, 2014).

La teledetección es una técnica que permite adquirir imágenes de la superficie terrestre mediante sensores instaladas en plataformas aéreas o espaciales, obteniendo información sobre la interacción energética que ocurre entre la superficie de interés y el sensor. Esta interacción puede darse por reflexión de la energía solar (sensores ópticos), un haz energético artificial (sensores radar) o por emisión propia de la superficie (sensores térmicos) (Chuvienco, 2010). A su vez, la señal recibida y transformada por el sensor debe transmitirse a la superficie terrestre para ser almacenada, procesada y analizada, con el fin de obtener su posterior interpretación. Actualmente, existe una gran variedad de sensores y plataformas espaciales que generan abundante información para el estudio de la superficie terrestre.

Entre las ventajas de utilizar esta técnica se encuentra:

- La capacidad de estudiar imágenes de áreas extensas
- Obtener información de lugares de difícil acceso o dispersos
- Realizar seguimientos repetitivos para estudiar procesos dinámicos
- Disminuir los esfuerzos y costos del levantamiento de datos en terreno

Un sistema de teledetección se compone de los siguientes elementos (Chuvienco,2010):

- Fuente de energía
- Cubierta Terrestre
- Sistema sensor
- Sistema de recepción
- Comercialización
- Interprete
- Usuario Final

Existen tres formas de teledetección determinadas por cómo es la interacción entre la superficie y el sensor, se puede establecer un flujo energético por:

- Reflexión: Cuando el sensor capta la energía proveniente del sol reflejada por la superficie terrestre
- Emisión: cuando los elementos presentes en las cubiertas terrestres emiten energía que puede detectar el sensor
- Emisión-Reflexión: cuando es el propio sensor quien emite y capta la onda una vez reflejada en el objeto que se pretende estudiar

En cualquiera de los casos mencionados, el flujo energético entre la cubierta terrestre y el sensor se manifiesta en forma de radiación electromagnética. Las propiedades de esta radiación han sido descritas por dos teorías aparentemente opuestas: la teoría cuántica, desarrollada por Planck y Einstein, y la teoría ondulatoria, desarrollada por Huygens y Maxwell. Aunque inicialmente parecen contradictorias, ambas teorías son complementarias, ya que se ha demostrado que la luz exhibe comportamientos que pueden explicarse desde ambos planteamientos (Chuvienco, 2010).

Según la teoría ondulatoria, la energía electromagnética se transmite de manera continua y armónica, viajando a la velocidad de la luz. Esta transmisión incluye dos campos de fuerza ortogonales entre sí: el campo eléctrico y el campo magnético. Las características de este flujo energético se describen principalmente a través de dos parámetros: la longitud de onda (λ) y la frecuencia (ν), los cuales están inversamente relacionados.

Por su parte, la teoría cuántica describe la radiación electromagnética como una sucesión de unidades discretas de energía denominadas fotones o cuantos, cuya masa es igual a cero. Esta teoría permite calcular la energía de un fotón a partir de su frecuencia, estableciendo que a mayor frecuencia corresponde una mayor cantidad de energía (Chuvieco, 2010).

En resumen, a mayor longitud de onda o menor frecuencia, el contenido energético será más bajo, y viceversa. Esto implica que la radiación de longitudes de onda más largas es más difícil de detectar que la radiación de longitudes más cortas.

De esta manera, es posible definir cualquier tipo de radiación o energía radiante en función de su longitud de onda o frecuencia. Aunque la sucesión de longitudes de onda es continua, se han establecido una serie de bandas en las que la radiación electromagnética muestra comportamientos similares. La organización de estas bandas según su longitud de onda es lo que se conoce como el espectro electromagnético (Figura N°3) (Chuvieco, 2010).

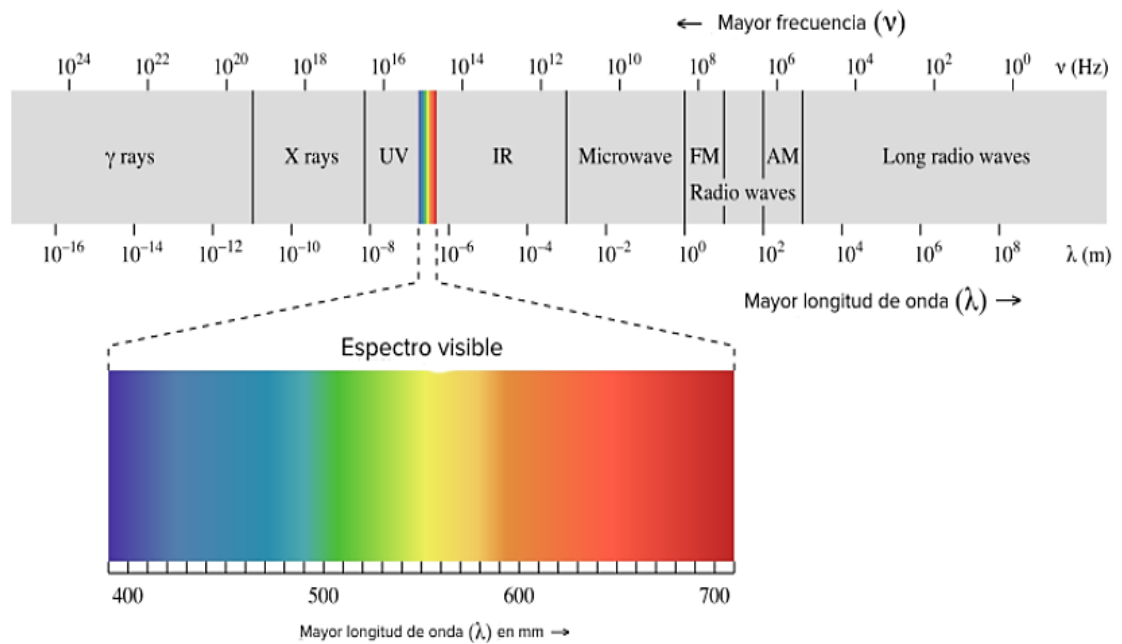


Figura N°3: Espectro electromagnético

Fuente: khanacademy.org

Desde el punto de vista de la teledetección, se destacan varias bandas espectrales de uso frecuente, entre las que se encuentran el espectro visible, el infrarrojo cercano, el infrarrojo medio, el infrarrojo lejano y las microondas. Para que la radiación emitida o reflejada por la superficie terrestre sea captada por el sensor con la mínima interferencia, se seleccionan zonas específicas del espectro electromagnético, debido a la interacción de esta radiación con la atmósfera.

La interacción de la radiación con la atmósfera y otros elementos terrestres varía según la longitud de onda y las características del objeto o cuerpo en cuestión. Los gases y aerosoles presentes en la atmósfera tienen un efecto triple sobre la radiación:

- Absorción en determinadas bandas del espectro.
- Dispersión de la radiación en ciertas bandas.
- Emisión, debido a su temperatura, con un pico máximo en el infrarrojo térmico.

Estas interacciones hacen que la atmósfera sea un factor clave a la hora de analizar los flujos de radiación entre el sol y la superficie terrestre, así como entre esta y los sensores instalados en plataformas satelitales.

En lo que respecta a la identificación de los objetos y procesos en la superficie terrestre, es crucial considerar la reflectividad de los objetos ante diferentes longitudes de onda. Cada tipo de cobertura (suelo, vegetación, agua, etc.) refleja la radiación incidente de manera distinta, lo que permite distinguir entre diferentes tipos de superficies midiendo la radiación reflejada. A partir de mediciones de laboratorio, se han obtenido datos de reflectividad para diversas coberturas a lo largo de diferentes longitudes de onda. El gráfico que representa la reflectividad en porcentaje para cada longitud de onda se conoce como firma espectral (Figura N°4), y constituye una especie de “huella digital” que identifica a cada objeto (Universidad de Murcia, 2003).

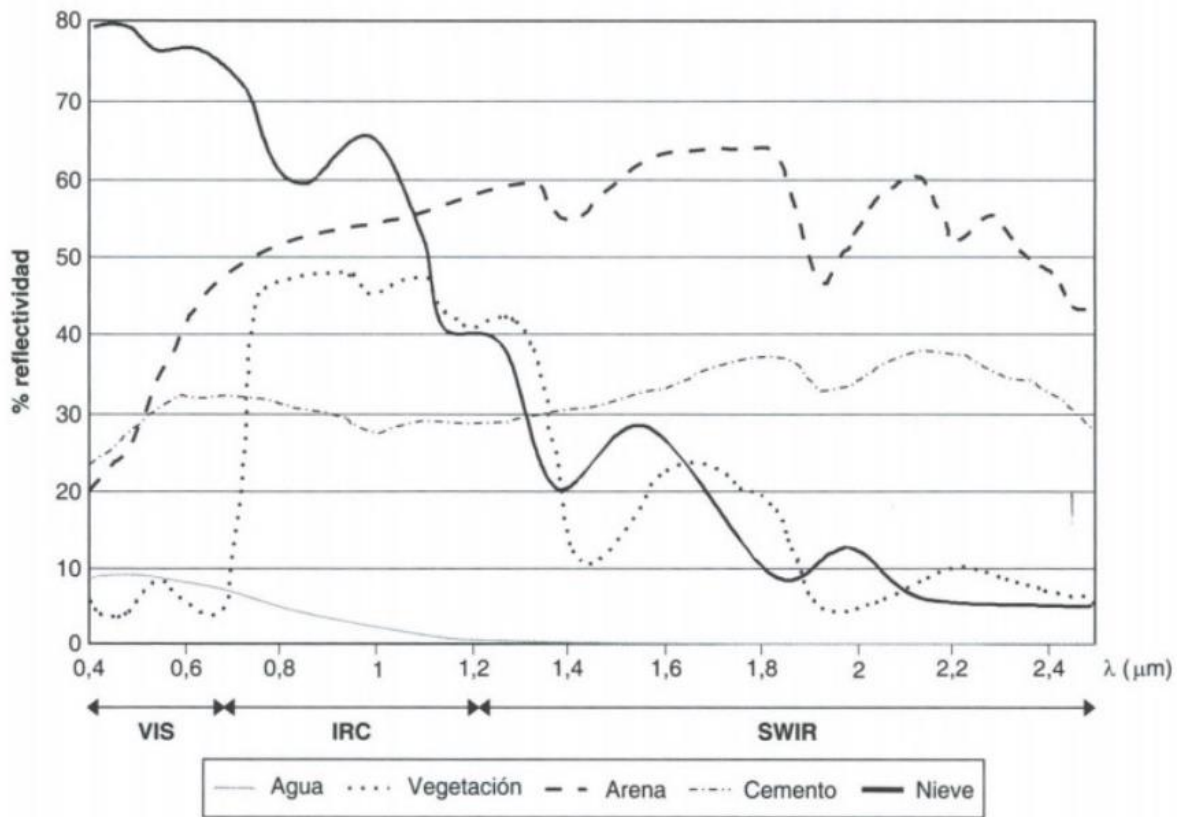


Figura N°4: Firmas espectrales típicas para distintas cubiertas

Fuente: Teledetección Ambiental, (Chuvieco, 2010)

3.4.1.- Tipos de Sensores

Los sensores remotos se clasifican, de manera general, en función de cómo reciben la energía de las distintas coberturas terrestres. De acuerdo con este criterio, existen dos tipos principales:

- Sensores pasivos: utilizan una fuente de energía externa, como la radiación solar.
- Sensores activos: emiten su propio haz de energía para captar la información

3.4.2.- Resolución del sistema sensor

La resolución de un sensor depende del efecto combinada de varios factores, lo que da lugar a diferentes tipos de resolución:

- Resolución espacial: Se refiere al tamaño del objeto más pequeño que puede ser distinguido en una imagen, y se mide en metros sobre el terreno. El elemento mínimo de información en una imagen es el píxel (elemento de imagen o "*picture element*"). Cuanto más pequeño sea el tamaño del píxel, menor será la probabilidad de que éste represente más de una cobertura adyacente. La resolución espacial es clave en la interpretación de la imagen, ya que determina el nivel de detalle que ésta ofrece, lo que está estrechamente ligado a la escala de trabajo y la fiabilidad de la interpretación (Chuvienco, 2010).
- Resolución espectral: Indica la cantidad y el ancho de las bandas espectrales que el sensor puede discriminar. Cuantas más bandas tenga un sensor, mayor será su capacidad para caracterizar diferentes coberturas espectrales. La elección del número, anchura y localización de las bandas está directamente relacionada con los objetivos para los que el sensor ha sido diseñado (Chuvienco, 2010).
- Resolución radiométrica: Hace referencia a la sensibilidad del sensor, es decir, a su capacidad para detectar pequeñas variaciones en la radiancia espectral que recibe. Una mayor resolución radiométrica permite distinguir objetos con niveles de reflectividad muy similares. Las imágenes se codifican en formato binario, por lo que la resolución radiométrica se expresa en términos del rango de valores que puede almacenar el sensor, medido en bits (Chuvienco, 2010).
- Resolución temporal: Se refiere a la frecuencia con la que un sensor adquiere imágenes de la misma zona de la superficie terrestre. Esta periodicidad depende de las características orbitales de la plataforma en

la que se encuentra el sensor (altura, velocidad, inclinación). La resolución temporal varía según los objetivos establecidos para el sensor (Chuvieco, 2010).

3.4.3.- Tipos de modelos en teledetección

En teledetección, los modelos se pueden clasificar en dos grandes categorías: aquellos que se basan en el diseño experimental para extraer principios teóricos (métodos estadísticos o modelos inductivos/empíricos) y aquellos que proponen estimaciones a partir del análisis de las relaciones teóricas entre los componentes de un problema determinada (modelos físicos o modelos teóricos/deductivos).

1. Modelos inductivos o empíricos:

Estos modelos intentan establecer una relación numérica entre el parámetro a estimar y los valores obtenidos por el sensor, basándose en observación in situ realizadas al momento de adquirir la imagen. Es decir, se generan funciones de ajuste local que vinculan los datos de la imagen con el parámetro de interés. La técnica de ajuste más común es la regresión, en sus diversas variantes, aunque también se han empleado redes neuronales en algunos casos (Chuvieco, 2010).

La principal ventaja de estos modelos es su simplicidad y la posibilidad de estimar su precisión usando las variables obtenidas in situ. Sin embargo, su principal desventaja es la limitada capacidad de generalización, ya que solo pueden aplicarse en condiciones similares a aquellas en las que fueron desarrollados (condiciones ambientales, tipo de sensor, rango de la variable estimada, condiciones atmosféricas, periodos de tiempo). Esto se debe a que agrupan todos los factores que relacionan la reflectancia con la concentración en un contexto específico.

2. Modelos teóricos o deductivos:

Estos modelos buscan establecer relaciones generales que sean independientes de las condiciones específicas de observación. Parten de demostrar la relación física entre el parámetro a estimar y la información espectral obtenida de la imagen. En la práctica, el objetivo es “invertir el modelo”, es decir, a partir de las observaciones de radiancia y reflectancia, se infieren los parámetros del modelo (Chuvieco, 2010).

La desventaja principal de estos modelos radica en el proceso de ajuste, que es complejo y, en ocasiones, impreciso, ya que requiere suponer condiciones ideales que rara vez se presentan en la naturaleza. No obstante, este tipo de modelos ofrece más posibilidades que los inductivos para estimar variables biofísicas mediante teledetección. Además, requieren menos muestreo in situ durante la adquisición de la imagen y son más generalizables a otros casos de estudio.

3.5.- Teledetección y cuerpos de agua

El agua se caracteriza por sus propiedades ópticas inherentes y aparentes. Las propiedades ópticas inherentes son aquellas que pertenecen al propio medio acuático y cuya magnitud y variación están determinadas por su composición y las sustancias presentes, independientemente de las condiciones lumínicas del momento (Sobrino, 2014). Por otro lado, las propiedades ópticas aparentes dependen tanto de las propiedades ópticas inherentes como de la energía incidente, así como de la forma y el lugar desde donde se observa la masa de agua.

Cuando la radiación incide sobre superficies líquidas, la mayor parte se refleja de manera especular (Figura N°5) en caso de que el agua esté muy tranquila. Sin embargo, cuando la superficie presenta rugosidad debido al oleaje, se favorece

la reflexión difusa (Figura N°5), dispersando la radiación en varias direcciones (Chuvieco, 2010).

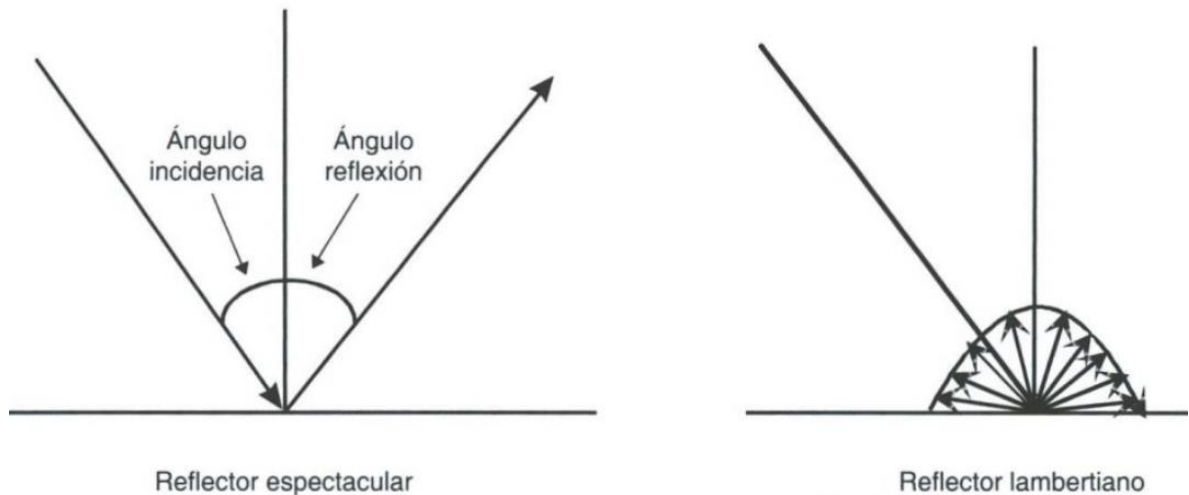


Figura N°5: Dirección especular (izquierda), reflector difuso ideal (derecha)

Fuente: Teledetección Ambiental (Chuvieco, 2010).

Solo una pequeña fracción de la radiación penetra en el agua, y parte de ella se refleja de manera difusa, fenómeno que se intensifica si existen partículas minerales en suspensión o fitoplancton. Además, la profundidad del agua influye directamente en su reflectividad, ya que, a menor profundidad, mayor será la reflectividad y menor la capacidad de absorción (Sobrino, 2014).

Las superficies de agua tienden a absorber o transmitir la mayor parte de la radiación visible que reciben, incrementando su capacidad de absorción a medida que aumenta la longitud de onda. La mayor reflectividad del agua ocurre en el espectro azul, disminuyendo hacia el infrarrojo cercano, donde es prácticamente nula. Por esta razón, la reflectividad del agua se detecta mejor en el intervalo óptico (longitudes de onda más cortas, como azul y verde), y esta reflectividad está relacionada con la profundidad y la cantidad de materiales en suspensión, como clorofila-a, partículas minerales y materia orgánica en suspensión (Sobrino, 2014).

Para lagos interiores, se ha observado que las longitudes de onda en el rango del visible y el infrarrojo cercano pueden relacionarse con parámetros de calidad del agua (Wu et al., 2008). Indicadores como la clorofila-a, materia disuelta total, turbidez, transparencia (medida como el disco de Secchi) y sustancias orgánicas disueltas han sido estimados con éxito utilizando técnicas de teledetección (Toming et al., 2016).

Dentro de los parámetros clave de la calidad del agua, el pigmento fotosintético clorofila-a es un indicador esencial de la biomasa del fitoplancton, por lo que su estimación es crucial para el monitoreo de la calidad del agua (Toming et al., 2016). Se ha observado que, en aguas con altas concentraciones de este pigmento, la reflectividad disminuye en las bandas del azul y del rojo, mientras que aumenta en la banda verde. Esto permite establecer una correlación negativa entre la reflectividad en la banda azul y el contenido de clorofila-a, y una correlación positiva entre la reflectividad en la banda verde y el contenido de clorofila-a. Esta relación facilita la detección de concentraciones de algas y el estudio del estado trófico de los cuerpos de agua (Chuvieco, 2010).

Los cambios en el color del agua provocados por la clorofila-a, que absorbe y refleja la luz incidente, permiten estimar este parámetro mediante teledetección, relacionando los cambios ópticos observados en la reflectancia a longitudes de onda específicas con las concentraciones de clorofila-a (Moses et al., 2019).

La efectividad de estas relaciones entre los parámetros de calidad del agua y los datos obtenidos mediante teledetección depende en gran medida de las características del cuerpo de agua. En aguas oceánicas profundas, el fitoplancton suele ser el constituyente predominante, y la concentración de otros componentes tiende a correlacionarse con la de clorofila-a. Por lo tanto, las características ópticas de estas aguas, denominadas aguas Caso-I, están dominadas por el fitoplancton. En estas aguas, las características espectrales de la luz reflejada pueden relacionarse directamente con la concentración de

clorofila-a. Los algoritmos espectrales que utilizan reflectancias en las bandas azul y verde del espectro han demostrado ser precisos en la estimación de la concentración de clorofila-a en este tipo de aguas (Moses et al., 2009).

Sin embargo, en la mayoría de las aguas continentales, estuarinas y costeras, los constituyentes como los sólidos en suspensión y la materia orgánica disuelta suelen estar presentes en abundancia, y sus concentraciones no están correlacionadas con la concentración de clorofila. Por lo tanto, en estas aguas productivas y turbias, comúnmente denominadas aguas Caso II, el fitoplancton no domina las propiedades ópticas. La complejidad óptica de estas aguas, especialmente las absorciones superpuestas y no correlacionadas de la materia orgánica disuelta y otras partículas suspendidas en la región azul del espectro, provoca que las relaciones azul-verde sean imprecisas para estimar las concentraciones de clorofila-a (Moses et al., 2009).

Además, las mismas especies de fitoplancton pueden desarrollar diferentes propiedades ópticas según su historial de exposición a la luz y los nutrientes que reciben. Diferentes especies de fitoplancton pueden presentar propiedades ópticas distintas, incluso cuando tienen las mismas concentraciones de clorofila en un cuerpo de agua. Asimismo, los diversos tipos de minerales o sus combinaciones interactúan de manera distinta con la luz. Es esencial tener en cuenta las características ópticamente importantes de las partículas, como su composición (tipo de partícula), estructura interna, distribución de tamaños y concentración (Mobley et al., 2003).

Debido a estas complejidades, para estimar las concentraciones de clorofila-a en aguas turbias y productivas, Moses et al. (2009) sugieren que es preferible utilizar algoritmos espectrales basados en la reflectancia de las regiones del rojo y el infrarrojo cercano (NIR).

Por otro lado, la heterogeneidad espacial dentro de un cuerpo de agua puede ser tan significativa que las mediciones in situ en un punto específico no representen adecuadamente el área abarcada por los píxeles satelitales (Moses et al., 2009).

3.6.- Sentinel-2

La misión Sentinel-2 es parte del programa europeo Copernicus, diseñada para capturar imágenes multispectrales de alta resolución y amplio barrido. Esta misión está compuesta por dos satélites gemelos que orbitan la Tierra en la misma órbita, pero separados por 180° como se ilustra en la Figura N°6, lo que permite obtener imágenes con una alta frecuencia de revisita. Esta característica es fundamental para el monitoreo continuo y preciso de diversas superficies terrestres, como cuerpos de agua, vegetación, y suelos, lo que convierte a Sentinel-2 en una herramienta clave para la observación y análisis ambiental.

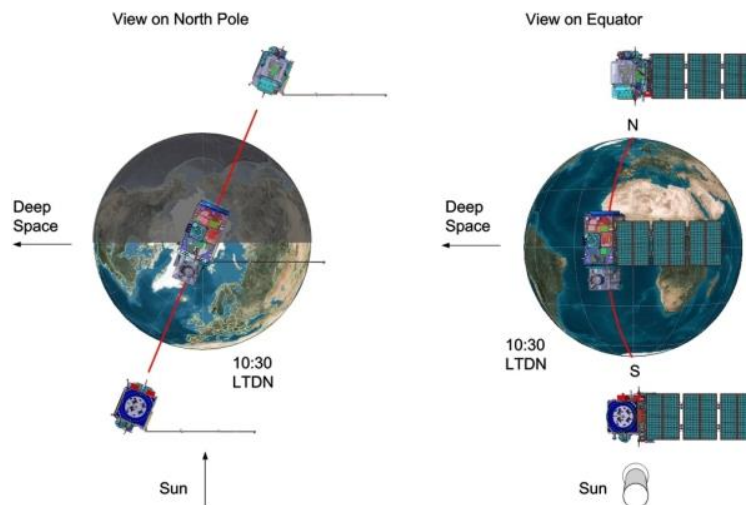


Figura N°6: Configuración Orbital de los satélites gemelos Sentinel-2 (European Space Agency)

Sentinel-2 transporta un sensor óptico llamada MSI (*MultiSpectral Instrument*), que captura imágenes en 13 bandas espectrales: cuatro bandas con resolución espacial de 10 metros, seis bandas a 20 metros y tres bandas a 60 metros. Su resolución radiométrica de 12 bits permite, en la práctica, estudiar incluso cuerpos de agua pequeños (Toming et al., 2016).

Aunque el principal objetivo de Sentinel-2 es el monitoreo global de áreas terrestres, diversos estudios han demostrado su potencial para evaluar la calidad de aguas continentales (Molkov et al., 2019; Barraza-Moraga et al., 2022; Toming et al., 2016). Gracias a la mejora en la resolución espacial y su alta frecuencia de adquisición de imágenes (cada 2 a 3 días), se ha logrado estimar exitosamente la concentración de clorofila-a en lagos utilizando algoritmos que correlacionan datos obtenidos in situ con la reflectancia de las bandas de Sentinel-2 (Barraza-Moraga et al., 2022).

Un desafío importante a considerar es la corrección atmosférica de las imágenes de cuerpos de agua (Toming et al., 2016). En estudios comparativos entre imágenes corregidas atmosféricamente (BOA, *Bottom of Atmosphere*) y no corregidas (TOA, *Top of Atmosphere*), se ha observado que en ocasiones las imágenes TOA proporcionan mejores resultados. Sin embargo, al utilizar datos TOA es importante tener en cuenta que los valores de reflectancia pueden verse influenciados por efectos atmosféricos (Barraza-Moraga et al., 2022). Además, se ha observado que la corrección atmosférica puede reducir la correlación entre los algoritmos que relacionan las bandas de Sentinel-2 con los datos in situ, lo que sugiere la necesidad de aplicar correcciones atmosféricas específicas para cuerpos de agua. Esto indica que las reflectancias corregidas BOA proporcionadas por Sentinel-2 no siempre son adecuadas para estos estudios (Toming et al., 2016).

3.7.- Modelos Lineales

Los modelos basados en regresión lineal han sido ampliamente utilizados para predecir parámetros de calidad del agua a partir de reflectancia satelital (Abbas & Alameddine, 2023). Diversos estudios han demostrado la utilidad de estos modelos de regresión lineal múltiple en la predicción de parámetros de calidad del agua. Por ejemplo, (Barraza-Moraga et al., 2022) desarrollaron varios modelos de regresión lineal considerando factores como la estación del año, la influencia de valores atípicos y la comparación entre datos BOA y TOA. Como resultado obtuvieron mapas de concentración de clorofila-a para el lago Lanalhue en los periodos de invierno-otoño y primavera-verano, con un rendimiento de los modelos superior a $R^2 > 0.87$.

De manera similar, (Jang et al., 2024) emplearon un enfoque de regresión lineal múltiple para estimar la concentración de clorofila-a en un pequeño embalse utilizando distintos algoritmos y ratios de bandas de Sentinel-2. A pesar de las complejas condiciones de calidad del agua, lograron un rendimiento relevante, con $R^2 = 0.65$, lo que permitió obtener una distribución espacio-temporal de clorofila-a en el embalse.

En otro estudio, (Ivanda et al., 2021) ajustaron un modelo de regresión múltiple empleando *Ridge Regression* para mitigar los efectos de la multicolinealidad entre las bandas, logrando un modelo capaz de estimar la concentración de clorofila-a con un coeficiente de determinación de $R^2 = 0.685$. Este estudio concluyó que es posible encontrar correlaciones significativas entre los valores de reflectancia de las bandas y sus transformaciones con la concentración medida de clorofila-a en aguas oligotróficas, donde los valores de clorofila-a son bajos.

Por otra parte, (Abbas & Alameddine, 2023), utilizando datos del sensor MSI de Sentinel-2 para estimar diversos parámetros de calidad del agua, compararon el rendimiento de cuatro tipos de modelos y sugirieron la importancia de explorar el

uso de estructuras de modelos más allá de la regresión lineal. Señalaron que los algoritmos de modelos más complejos pueden captar relaciones no lineales más detalladas entre los parámetros de calidad del agua y las mediciones de reflectancia superficial, obteniendo mejores ajustes en comparación con los modelos lineales.

Estos estudios indican que, aunque los modelos de regresión múltiple permiten establecer relaciones estadísticamente significativas entre la reflectancia satelital y los parámetros de calidad del agua, su aplicabilidad es específica de cada sitio. Esto dificulta la extrapolación de los resultados a otras áreas de estudio, ya que los modelos deben desarrollarse y ajustarse para cada sitio particular. Considerando esto, estos modelos son clasificados como inductivos, según los tipos de modelos empleados en teledetección descritos por (Chuvieco, 2010).

4.- Metodología

4.1.- Área de estudio

El área de estudio de este trabajo se encuentra en la ecorregión de los lagos valdivianos-araucanos. Estos cuerpos de agua se caracterizan por presentar, en su totalidad, concentraciones de clorofila clasificadas como oligotróficas. Esta condición está relacionada con la baja presión antrópica ejercida sobre ellos y con el clima de la región, que se caracteriza por abundantes precipitaciones y bajas temperaturas. En esta zona se encuentran algunos de los cuerpos de agua más extensos, que abarcan áreas de la depresión intermedia, la cordillera y la precordillera de los Andes (DGA, 2014).

El lago Llanquihue está ubicado en la región de los Lagos, dentro de la cuenca del “Río Maullín” y la subcuenca del “Lago Llanquihue”. Es el segundo lago más grande de Chile, con una superficie aproximada de 870,5 km², una longitud máxima de 42 km, una profundidad máxima de 317 m, y un volumen de 158,6 km³. El lago es de origen pluvial, tiene características exorreicas y su único desagüe es el río Maullín.

Entre sus características hidrológicas destacan la reducida superficie de su cuenca aportante en relación con la extensión del espejo de agua, y la pequeña magnitud de sus afluentes, entre los que se incluyen los ríos Pescado, Blanco, Blanco Las Cascadas, Blanco Arenal, Tepú, Tempe y estero Puma. Además, el caudal de su único desagüe es limitado. Estas condiciones hacen que el principal aporte de agua al lago provenga de las precipitaciones directas sobre su superficie, lo que contribuye a que la renovación teórica de sus aguas se estime en 74 años (NSCA,2010).

El lago Llanquihue ha sido clasificado como un lago monomítico de invierno, lo que significa que sus aguas se mezclan una vez al año, principalmente durante el invierno debido a los cambios de la temperatura. La estratificación máxima se

produce en los primeros días de febrero, y la termoclina se sitúa a una profundidad de 40 metros en verano.

Este lago fue incorporado a la red mínima de lagos en 1986, tras identificarse problemas de contaminación localizados, principalmente causados por descargas de aguas servidas sin tratamiento desde localidades urbanas cercanas. Como resultado, se establecieron monitoreos estacionales desde ese mismo año.

Además, el lago Llanquihue fue el primer lago en contar con una norma secundaria de calidad ambiental, establecida mediante Decreto Supremo 122, publicado en el Diario Oficial el 4 de junio de 2010. Esta normativa fue desarrollada en base a los antecedentes recopilados por la red mínima de lago.

Dado el pequeño tamaño de su cuenca y la baja magnitud de sus afluentes, el principal riesgo para la calidad del agua proviene de las actividades humanas desarrolladas en el lago y sus alrededores, tales como las pisciculturas y el vertimiento de residuos (Abarca Mesa, 2014).

Para este estudio, se consideraron las aguas superficiales del lago Llanquihue (0 a 5 metros de profundidad) y se utilizaron las estaciones de monitoreo mensual del centro EULA detalladas en la Tabla N°1, realizadas durante un año, desde el 12 de octubre de 2020 hasta el 7 de septiembre de 2021, aplicando además un buffer de 150 metros a las estaciones como se muestra en la Figura N°7.

Tabla N°1: Estaciones de Monitoreo EULA

Nombre estación	UTM Norte	UTM Este
Ensenada	5436631	701759
Ensenada Litoral	5435017	704835
Frutillar N°2	5444371	671991
Frutillar Litoral	5443470	666298
Puerto Octay N°2	5457120	680704
Puerto Octay Litoral	5460236	678974
Puerto Varas N°2	5429534	673039
Puerto Varas Litoral	5423617	670115

Fuente: Elaboración propia




Figura N°7: Ubicación área de estudio y estaciones de monitoreo

Elaboración Propia

4.2.- Google Earth Engine

Google Earth Engine (GEE) es una Plataforma gratuita basada en la nube, diseñada por Google para el análisis geoespacial a gran escala. Esta plataforma permite a los usuarios acceder a una vasta cantidad de datos geoespaciales, incluidas imágenes satelitales y otros conjuntos de datos ambientales, facilitando su procesamiento sin la necesidad de grandes recursos locales de almacenamiento o infraestructura computacional. Esto ha revolucionado el análisis de datos espaciales, permitiendo realizar cálculos que tradicionalmente requerían una gran infraestructura. GEE aloja más de 40 años de datos de observación de la Tierra provenientes de diversas misiones satelitales, como Landsat, MODIS y Sentinel-2, lo que la convierte en una herramienta esencial para estudios de cambio climático, monitoreo ambiental y gestión de recursos naturales (Gorelick et al., 2017). Además, GEE proporciona herramientas de programación y una extensa biblioteca de datos que permiten a los usuarios realizar análisis mediante código, lo que reduce significativamente el tiempo necesario para descargar y procesar imágenes satelitales, simplificando el flujo de trabajo y haciendo más accesible la gestión de información satelital (Barraza-Moraga et al., 2022).

Además de su extenso repositorio de datos y su capacidad para procesarlos eficientemente, un componente clave para el funcionamiento de Google Earth Engine (GEE) son sus API. Una API (interfaz de programación de aplicaciones) permite la comunicación entre los usuarios y los servidores de Google, facilitando el acceso y uso de la capacidad computacional de la plataforma para realizar análisis complejos. Las API de GEE están diseñadas para simplificar la creación de programas mediante una serie de funciones, métodos y algoritmos preprogramados, los cuales pueden ser invocados por una simple línea de código (Solórzano & Perilla, 2022).

GEE ofrece dos API principales: una en JavaScript, accesible a través de un navegador web, que es la más popular, actualizada y con mayor documentación y otra en Python, que se ejecuta desde la consola de Python y permite complementar su funcionalidad con bibliotecas externas para procesamientos más avanzados que la API de JavaScript no admite (Solórzano & Perilla, 2022).

4.3.- Elaboración de la base de datos

Para la creación de la base de datos con las imágenes satelitales de Sentinel-2, se accedió a las colecciones de imágenes disponibles en *Google Earth Engine*, específicamente al nivel 1-C, que corresponde a la reflectancia de la parte superior de la atmósfera (TOA, por sus siglas en inglés).

Para gestionar estas colecciones, se aplicaron varios filtros: un filtro temporal que abarcó el periodo de interés (15/10/2020 – 07/09/2021), un filtro de nubosidad que limitaba las imágenes con una fracción de nubes inferior al 30%, y un filtro geométrico que delimitaba un área de interés, en este caso, un cuadrado que contenía al lago.

Con base en el muestreo in situ, se generó una lista con cada una de las fechas de muestreo para aplicar una función que buscara, dentro de la colección de imágenes Sentinel-2 filtrada en *Google Earth Engine*, aquellas imágenes más cercanas a las fechas de muestreo, con un margen máximo de 5 días. Para esto se utilizó el método *closest* del paquete de Python *eemont*, el cual extiende algunas herramientas de GEE. Este filtro permitió crear una nueva colección que contenía únicamente las imágenes más cercanas a las fechas del muestreo in situ.

Para seleccionar las imágenes que incluían el lago en su totalidad, se utilizó el identificador único de grilla asociado a cada imagen, considerando solo aquellas que cubrían la zona del lago.

Posteriormente, se aplicó un buffer de 150 metros alrededor de los puntos de las estaciones de monitoreo para obtener los datos de las imágenes Sentinel-2. A través de una estadística zonal, se extrajo el promedio de cada una de las bandas espectrales dentro de la zona del buffer para cada imagen de la colección. Todos los datos de las bandas fueron exportados en formato CSV y se tabularon junto a las mediciones in situ. El diagrama en la Figura N°8 representa los pasos y filtros seguidos para la elaboración de la base de datos.

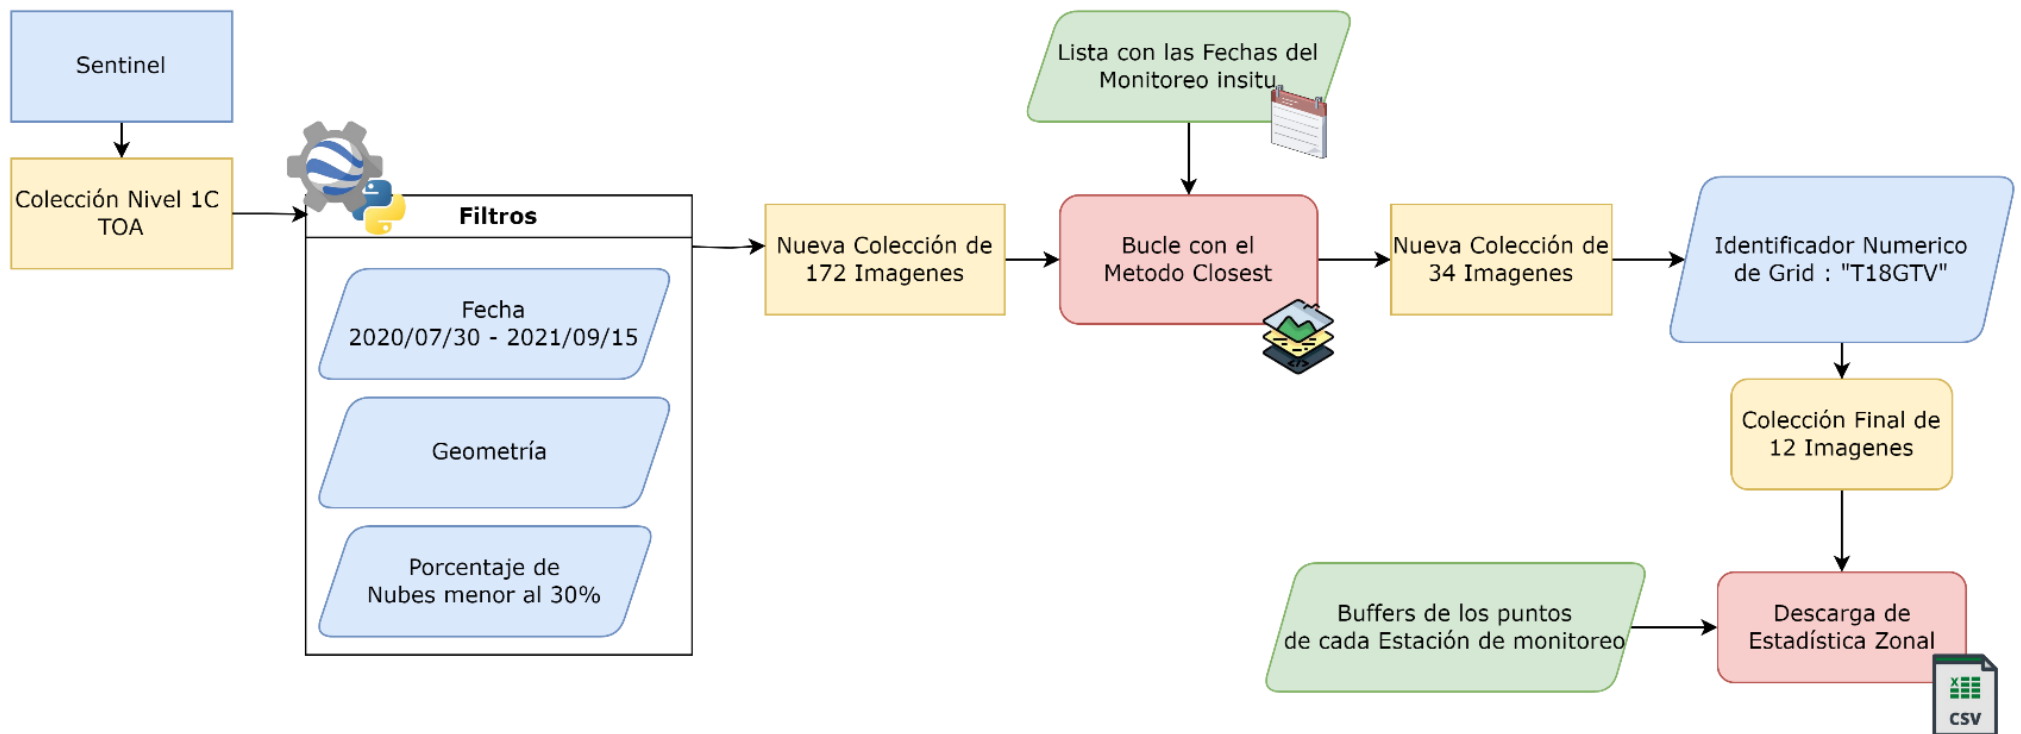


Figura N°8: Filtro de información satelital para la elaboración de la base de datos

Elaboración Propia a través de Draw.io

4.4.- Análisis preliminar de los datos

Antes de proceder con el análisis, se eliminaron de la base de datos aquellas mediciones de clorofila-a correspondientes a estaciones para las cuales no fue posible extraer información espectral. Asimismo, para evitar el uso de datos provenientes de estaciones que presentaban nubosidad en las imágenes satelitales, se excluyeron aquellas estaciones donde los valores de la Banda 9, que corresponde al vapor de agua, superaran los 100. Este umbral se estableció tras identificar un patrón en el análisis visual de las imágenes.

Una vez que los datos fueron depurados se procedió a realizar el análisis y generar los gráficos correspondientes a la distribución y correlación de las variables.

4.5.- Regresión Lineal múltiple

La regresión lineal múltiple es un método estadístico que modelo la relación entre una variable continua (dependiente) y dos o más variables independientes mediante el ajuste de una ecuación lineal. Este modelo asume que, dado un conjunto de observaciones, la media de la variable dependiente se relaciona linealmente con las variables independientes, de acuerdo con la siguiente ecuación:

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i$$

El resultado de esta ecuación recoge la relación entre los predictores y la media de la variable respuesta.

La interpretación de los de los elementos del modelo es:

- β_0 : es la ordenada en el origen y corresponde al valor promedio de la variable dependiente y , cuando todos los predictores son cero
- β_j : Representa el efecto promedio que tiene un incremento de una unidad en la variable predictora x_j sobre la variable dependiente, manteniendo

constantes las demás variables. Estos son conocidos como coeficientes parciales de regresión.

- ϵ : es el residuo o error, que representa la diferencia entre el valor estimado y el valor observado por el modelo. Este término recoge el efecto de todas las variables que influyen en la variable dependiente pero que no se incluyen como predictores en el modelo.

Dado que los valores poblacionales de β_0 y β_j son desconocidos, se obtienen sus estimaciones $\hat{\beta}_0$ y $\hat{\beta}_j$ a partir de una muestra. Ajustar el modelo consiste en estimar, utilizando los datos disponibles, los valores de los coeficientes de regresión que maximizan la verosimilitud. Es decir, se busca el modelo que con mayor probabilidad podría haber generado los datos observados (Amat Rodrigo, 2024).

El método empleado en este trabajo es el ajuste por mínimos cuadrados ordinarios (OLS), que identifica como el mejor modelo la recta (o plano, en el caso de una regresión múltiple) que minimiza la suma de las desviaciones verticales al cuadrado entre cada dato de entrenamiento y la recta.

Una vez estimados los coeficientes, se pueden obtener las estimaciones para cada observación utilizando la siguiente fórmula:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_p x_{ip}$$

4.6.- Relación entre variables

El primer paso a la hora de crear un modelo de regresión lineal múltiple es estudiar la relación que existe entre variables. Esta información es útil para identificar cuáles pueden ser los mejores predictores para el modelo y para detectar colinealidad entre ellos. Para generar la matriz de correlaciones, se relacionaron todas las variables utilizando el método de Spearman, y se graficaron en forma de matriz con Python. Además, se graficó la distribución de cada variable.

4.7.- Selección de Predictores

Método paso a paso (*stepwise*): Este método emplea criterios matemáticos para determinar qué predictores contribuyen significativamente al modelo y en qué orden se deben introducir. Para este trabajo se utilizaron dos estrategias:

- Dirección *Forward*: El modelo inicial no contiene ningún predictor, solo el parámetro β_0 . A partir de este, se generan todos los posibles modelos introduciendo una sola variable de entre todas las disponibles. La variable que mejora en mayor medida el modelo se selecciona. Luego, se intenta incrementar el modelo probando a introducir una a una las variables restantes. Si alguna de ellas mejora el modelo, también se selecciona.
- Dirección *Backward*: El modelo se inicia con todas las variables disponibles incluidas como predictores. Se prueba a eliminar cada variable una a una; si la eliminación de alguna mejora el modelo, esta queda excluida. Este método permite evaluar cada variable en presencia de las demás.

El método paso a paso requiere de algún criterio matemático para determinar si el modelo mejora o empeora con cada incorporación o extracción de variables. Existen varios parámetros que se pueden utilizar, destacando el BIC, AIC y el R^2_{ajustado} . En este trabajo se utilizó el R^2_{ajustado} (Amat Rodrigo, 2024).

Las dos metodologías fueron implementadas mediante una función en Python para seleccionar los predictores y luego ajustar el modelo con las variables seleccionadas.

4.8.- Bondad de Ajuste del Modelo

Una vez ajustado el modelo, es necesario verificar su utilidad, ya que, aunque sea la línea que mejor se ajusta a las observaciones, puede presentar un error considerable. Las métricas más utilizadas para medir la calidad del ajuste son el error estándar de los residuos y el coeficiente de determinación R^2 .

Coeficiente de Determinación R^2 : El R^2 describe la proporción de la varianza de la variable respuesta explicada por el modelo en relación con la varianza total. Su valor varía entre 0 y 1 y es adimensional:

$$R^2 = 1 - \frac{\sum(\hat{y}_i - y_i)^2}{\sum(y_i - \bar{y})^2}$$

En los modelos de regresión lineal múltiple, cuanto más predictores se incluyan en el modelo, mayor será el valor de R^2 , ya que incluso el predictor más pequeño explica parte de la variabilidad observada en y . Por este motivo, R^2 no puede ser utilizado para comparar modelos con diferente número de predictores.

El R^2 ajustado introduce una penalización al valor de R^2 por cada predictor adicional en el modelo. Esta penalización depende del número de predictores y del tamaño de la muestra. El R^2 ajustado permite identificar el mejor modelo, aquel que explica mejor la variabilidad de y con el menor número de predictores

$$R^2_{ajustado} = R^2 - (1 - R^2) \frac{n - 1}{n - p - 1}$$

Donde n es el tamaño de la muestra y p el número de predictores.

Otro indicador para evaluar el desempeño de los modelos de regresión lineal múltiple es el *Root Mean Squared Error* (RMSE). Generalmente, mientras menor sea el RMSE, mejor será el rendimiento del modelo. Singh et al. (2004) sostienen que valores de RMSE inferiores a la mitad de la desviación estándar de los datos medidos pueden considerarse bajos (Moriassi et al., 2007).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2}$$

La eficiencia de Nash-Sutcliffe (NSE), propuesta por Nash y Sutcliffe, es un estadístico que compara la varianza residual con la varianza de los datos medidos. Un NSE = 1 indica un ajuste perfecto entre los datos observados y los simulados, mientras que un NSE = 0 indica que el modelo tiene la misma capacidad predictiva que la media de las observaciones. Valores de NSE menores que 0 indican que el modelo es un peor predictor que la media de las observaciones (Barraza-Moraga et al., 2022).

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$$

El *Percent Bias* (PBIAS) mide la tendencia promedio de los datos simulados a ser mayores o menores que los observados. El valor óptimo de PBIAS es 0,0 y valores bajos indican una simulación precisa. Valores positivos indican un sesgo de subestimación del modelo, mientras que valores negativos reflejan un sesgo de sobreestimación (Moriasi et al., 2007). El PBIAS se calcula con la siguiente ecuación:

$$PBIAS = \frac{\sum_{i=1}^n O_i - P_i}{\sum_{i=1}^n O_i} * 100$$

4.9.- Diagnóstico del Modelo de Regresión

Para validar los supuestos del modelo de regresión lineal múltiple (linealidad, homocedasticidad, normalidad e independencia), es fundamental analizar el comportamiento de los residuos. Los residuos son la diferencia entre los valores reales de la variable dependiente y los valores estimados por el modelo.

El diagnóstico se realiza principalmente mediante la visualización gráfico de los residuos, lo que permite evaluar si los supuestos se cumplen:

- Linealidad: El supuesto de linealidad implica que la relación entre las variables independientes y la dependiente es lineal. Esto se puede verificar observando un gráfico de los residuos frente a los valores

predichos. Si los residuos se distribuyen de manera aleatoria, el supuesto se cumple.

- Homocedasticidad: Este supuesto indica que la varianza de los residuos es constante a lo largo de los valores predichos. En un gráfico de residuos frente a predicciones, la homocedasticidad se observa cuando los residuos no muestran patrones o “formas” y tienen una dispersión constante.
- Normalidad: Los residuos deben seguir una distribución normal. Esto se verifica mediante un histograma o un gráfico Q-Q (cuantiles-cuadrantes), que compara la distribución de los residuos con la distribución normal.
- Independencia: Los residuos deben ser independientes entre sí. Este supuesto se puede comprobar visualmente, aunque en algunos casos se emplean pruebas estadísticas.

Si los residuos no presentan patrones claros en los gráficos y siguen una distribución normal, se puede concluir que los supuestos del modelo de regresión se cumplen, lo que otorga validez a los resultados del modelo.

4.10.- Ajuste del Modelo

Statsmodels es una librería de Python que proporciona clases y funciones para la estimación de modelos estadísticos, así como para la realización de pruebas y la exploración de datos estadísticos. Una característica destacada de esta librería es que los resultados obtenidos son verificados en comparación con otros paquetes estadísticos, asegurando su precisión (Seabold & Perktold, 2010). En este trabajo, para ajustar los modelos se empleó la metodología de mínimos cuadrados ordinarios (OLS) disponible en *Statsmodels*, la cual permite estimar los coeficientes de un modelo de regresión minimizando la suma de los errores al cuadrado entre los valores observados y los estimados.

La librería no solo facilita el ajuste de modelos lineales, sino que también provee herramientas para analizar los resultados mediante la obtención de métricas

clave como el valor p , los intervalos de confianza, y el coeficiente de determinación, entre otros. Además, cuenta con herramientas para el diagnóstico del modelo, como gráficos de residuos y pruebas de normalidad, lo que permite evaluar si los supuestos de los modelos de regresión se cumplen.

4.11.- Colinealidad

La colinealidad ocurre cuando un predictor está linealmente relacionado con uno o varios de los otros predictores del modelo. Como consecuencia, no es posible identificar con precisión el efecto individual de cada predictor sobre la variable respuesta, lo que provoca un aumento en la varianza de los coeficientes de regresión estimados. Esto puede llevar a que los coeficientes pierdan significancia estadística. Además, pequeños cambios en los datos pueden causar grandes variaciones en las estimaciones de los coeficientes (Amat Rodrigo, 2024).

Un método estadístico comúnmente utilizado para detectar la colinealidad es el *Variance Inflation Factor* (VIF). Este índice mide cuánto se incrementa la varianza de un coeficiente de regresión estimado debido a la colinealidad. Valores de VIF altos indican una mayor colinealidad entre los predictores, lo que puede comprometer la estabilidad y precisión del modelo. Generalmente, un VIF superior a 10 se considera indicativo de problemas graves de colinealidad.

5.- Resultados

Para la generación de la base de datos se obtuvieron imágenes satelitales correspondientes a fechas cercanas a cada uno de los muestreos in situ. Los puntos de coincidencia indicados en la Tabla N°2 representan los puntos de las imágenes satelitales de los cuales se pudo extraer información útil. Durante la revisión de las imágenes, se observó que ocho de ellas no cubrían la totalidad del Lago Llanquihue, lo que llevó a la exclusión de tres estaciones de muestreo: Puerto Octay Litoral, Frutillar Litoral y Frutillar 2. Esta omisión se debe a las diferencias en la cobertura proporcionada por los satélites Sentinel-2A y Sentinel-2B, que operan con un desfase de 180° en sus órbitas. Mientras que el Sentinel-2^a cubre la totalidad del lago, el Sentinel-2B no abarca las estaciones mencionadas.

Por otro lado, las cuatro imágenes restantes cubrieron completamente el lago. Sin embargo, en una de ellas se observó una nubosidad significativa que afectó prácticamente la totalidad del lago, lo que impidió la extracción de datos espectrales. Esta imagen se encuentra representada en la Tabla N°2 con cero puntos de coincidencia. Las otras tres imágenes restantes, con mínima presencia de nubosidad, permitieron obtener información espectral para las ocho estaciones de muestreo.

En cuanto a la diferencia de días entre el muestreo in situ y la adquisición de la imagen satelital, la mayor diferencia observada fue de tres días en una sola imagen. Aunque diferencias de hasta ± 3 días se consideran aceptables, ya que no se espera que impacten significativamente los parámetros de calidad del agua, salvo en casos de floraciones algales (*blooms*) o intensas lluvias (Toming et al., 2016), es importante recordar que el lago es un sistema dinámico. Esto implica que las condiciones pueden variar entre el día del muestreo y el de la captura de la imagen satelital, lo que podría afectar los análisis de correlación.

Finalmente, en la Tabla N°2 se presentan los valores de concentración mínima y máxima de clorofila-a registrados en las estaciones durante los muestreos in situ, lo que permite visualizar los niveles de este parámetro para cada fecha de estudio.

Tabla N°2: Resumen de la Base de Datos generada

Fecha de Muestreo	Fecha Adquisición Imagen	Puntos de coincidencia	Días de diferencia	Concentración mínima Chl-a	Concentración máxima Chl-a
2020-10-15	2020-10-12	3	3	0.26	0.36
2020-11-17	2020-11-19	8	2	0.16	0.4
2020-12-22	2020-12-21	5	1	0.15	0.32
2021-01-18	2021-01-18	8	0	0.18	0.37
2021-02-09	2021-02-07	8	2	0.15	0.44
2021-03-16	2021-03-14	3	2	0.25	0.43
2021-04-14	2021-04-15	3	1	0.31	0.35
2021-05-12	2021-05-10	5	2	0.28	0.66
2021-06-16	2021-06-14	5	2	0.76	1.24
2021-07-14	2021-07-12	0	2	0.49	1.05
2021-08-09	2021-08-08	5	1	0.38	0.71
2021-09-07	2021-09-07	5	0	0.74	0.82

Fuente: Elaboración Propia

5.1.- Análisis Preliminar de los Datos

En la Figura N°9, se presenta un gráfico de caja que muestra la distribución de los datos de concentración de clorofila-a. Este gráfico permite visualizar la dispersión de los datos, la mediana y los valores atípicos. Se observa que la mayoría de los valores de concentración de clorofila-a están concentrados entre aproximadamente 0.25 y 0.60, con una mediana cercana a 0.40. Sin embargo, se identifican dos valores que se alejan considerablemente de los demás, ubicándose entre 1.1 y 1.2, los cuales corresponden a mediciones realizadas en Puerto Octay y Ensenada el 16/06/2021.

Aunque estos valores pueden considerarse atípicos, no hay evidencia que sugiera que se trate de errores de medición, por lo que fueron conservados en la base de datos para no comprometer la integridad del análisis. Además, la longitud de los bigotes indica la presencia de una variabilidad moderada en las mediciones de clorofila-a, con algunos puntos más alejados que otros, lo que podría estar relacionado con cambios naturales en la dinámica del lago.




Figura N°9: Grafico de caja de datos de concentración de clorofila-a
Elaboración Propia a través de Spyder

En el gráfico de distribución de variables de la Figura N°10, se observa que las variables clorofila-a y las bandas B2, B11 y B12 muestran una distribución sesgada hacia la derecha, lo que indica una tendencia exponencial en sus valores. Esto sugiere que una transformación logarítmica podría ser apropiada para normalizar estas distribuciones, facilitando el análisis de los datos en modelos que asumen normalidad.

Por otro lado, las bandas B5, B6, B7 y B8 presentan distribuciones que se asemejan más a una distribución normal, lo que indica que estos datos podrían ajustarse adecuadamente a modelos lineales sin necesidad de transformaciones adicionales. Las curvas ajustadas a los histogramas de estas bandas muestran una mayor simetría.

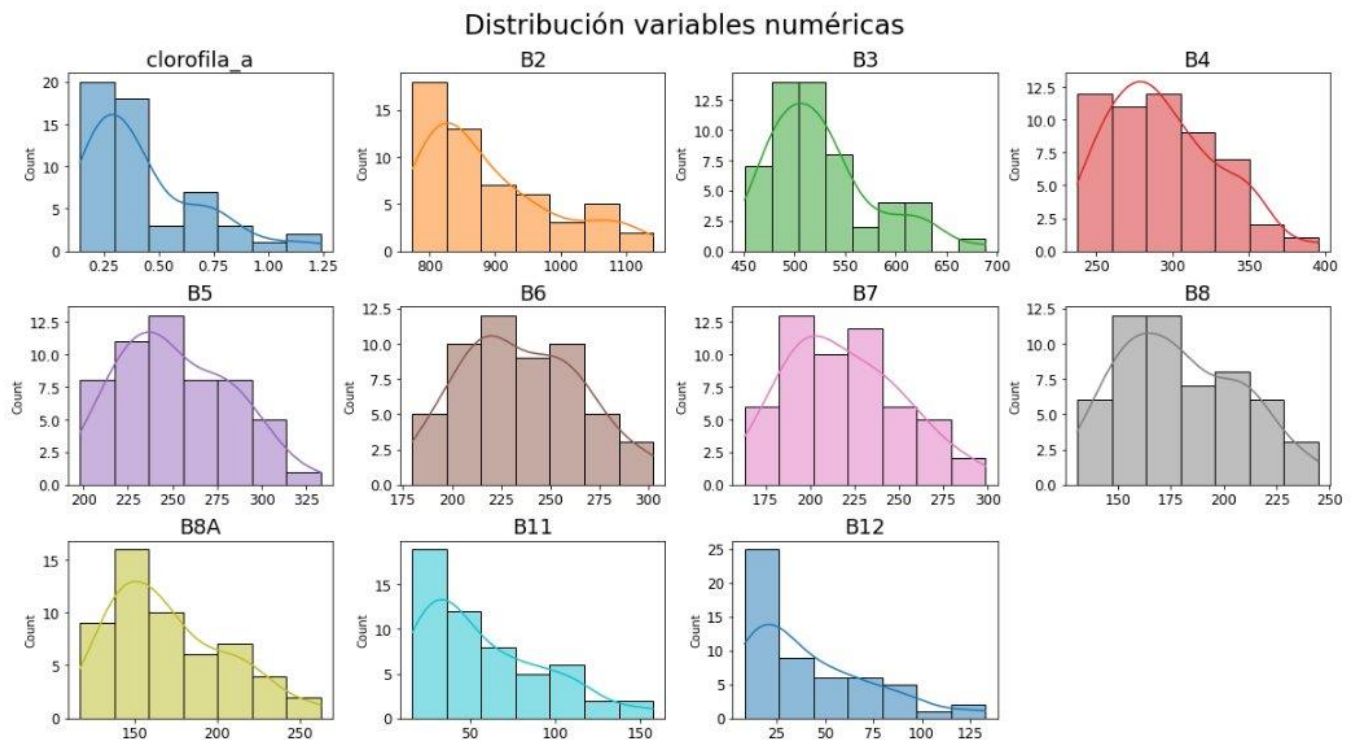


Figura N°10: Distribución de las variables numéricas

Elaboración Propia a través de Spyder

En la Figura N°11, se muestra la matriz de correlaciones que relaciona cada variable con las demás, representada en forma de matriz triangular. En cada celda, el valor numérico indica la fuerza y la dirección de la correlación entre las variables correspondientes, utilizando el coeficiente de correlación de Spearman, ya que los datos no presentan una distribución normal.

Se destaca la correlación positiva significativa entre la concentración de clorofila-a y las bandas B2 ($r = 0.63$, $p < 0.05$) y B3 ($r = 0.57$, $p < 0.05$). Estas correlaciones sugieren que el aumento en los valores de estas bandas del espectro está relacionado con mayores concentraciones de clorofila-a. Por otro lado, se observa una correlación negativa significativa entre la concentración de clorofila-a y las bandas B11 ($r = -0.57$, $p < 0.05$) y B12 ($r = -0.62$, $p < 0.05$), lo que indica que a medida que aumentan los valores en estas bandas, la concentración de clorofila-a tiende a disminuir.

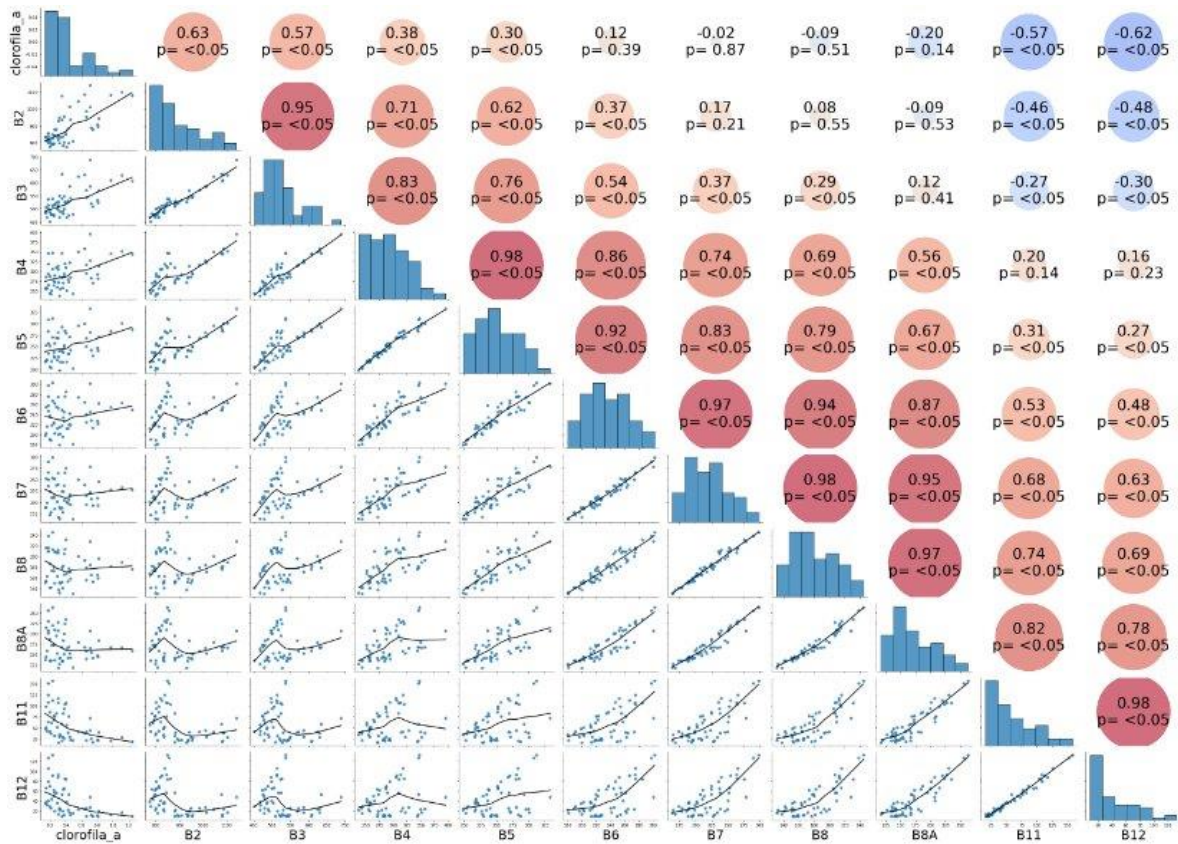


Figura N°11: Matriz de correlación utilizando el coeficiente de Spearman

Elaboración Propia a través de Spyder

Las transformaciones aplicadas a las variables clorofila-a, banda 11 y banda 12 muestran que la transformación logarítmica en base 10 mejora la simetría de la distribución de los datos, logrando que sea más cercana a una distribución normal. Esto se visualiza en la Figura N°12, donde los diagramas de caja permiten comparar cómo las diferentes transformaciones afectan la dispersión de las variables. En particular, la transformación logarítmica logra reducir la asimetría y la dispersión en los extremos de los datos, lo que indica que podría ser una estrategia adecuada para normalizar estas variables. Esto es útil para análisis de regresión ya que estos modelos asumen la normalidad de los datos.

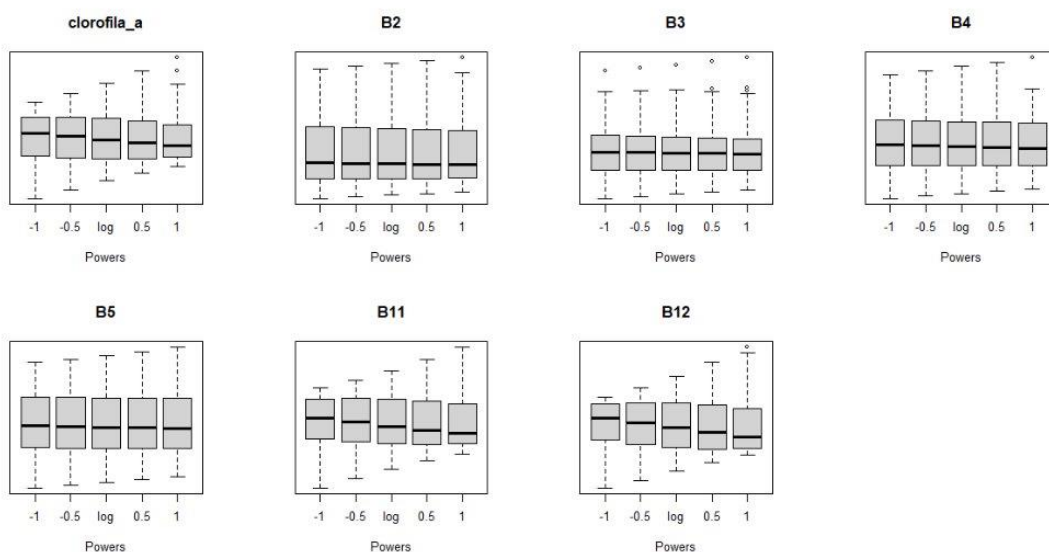


Figura N°12: Distribución de variables estadísticamente significativas y sus transformaciones
Elaboración Propia a través de RStudio

5.2.- Ajuste de Modelos

Se evaluó el desempeño de los ajustes utilizando el método de mínimos cuadrados ordinarios, considerando las variables que presentaron correlaciones estadísticamente significativas.

5.2.1.- Modelo 1

Dado que la transformación a logaritmo natural de las concentraciones de clorofila-a muestra un comportamiento más cercano a una distribución normal, se ajustó el modelo utilizando esta transformación como la variable dependiente. Para la selección de predictores, se incluyeron las variables que resultaron estadísticamente significativas en el análisis de correlación, es decir, las bandas [2, 3, 4, 5, 11, 12].

Los resultados obtenidos con las metodologías de selección de predictores están detallados en la Tabla N°3.

Tabla N°3: Selección de predictores Modelo 1

Método	Predictores
Forward	B2,B4,B11
Backward	B2,B4,B11

Fuente: Elaboración propia

En este caso utilizando ambos métodos fueron seleccionadas las mismas variables.

Tabla N°4: Coeficientes del Modelo 1

Variable	Coefficiente	Valor p
Intercepto	-0.4517	0.501
B2	-0.0122	0.00
B4	0.0412	0.00
B11	-0.0316	0.00

Fuente: Elaboración propia

Los resultados del modelo mostrados en la Tabla N°4 indican que la prueba de significancia de los predictores señala como significativos los coeficientes de las tres bandas seleccionadas. La ecuación del modelo ajustado con estos predictores es la siguiente:

Ec.1:

$$\ln([Chl - a]) = -0.4517 + (B2 * -0.0122) + (B4 * 0.0412) + (B11 * -0.0316)$$

Tabla N°5: Medidas de Bondad de Ajuste Modelo 1

Estadístico	Valor
R^2	0.743
$R^2_{ajustado}$	0.727
PBIAS	-1.37e-12
RMSE	0.281
NSE	0.743

Las medidas de bondad de ajuste representados en la Tabla N°5 sugieren que el modelo es capaz de explicar el 74.3% de la variabilidad en la concentración de clorofila-a, mientras que el $R_{ajustado}^2$ indica que el modelo puede explicar el 72.7% del comportamiento de este parámetro

El PBIAS mide la tendencia de los datos simulados a ser mayores o menores que los observados. En este modelo, el PBIAS es prácticamente cero, lo que indica que no existe una tendencia significativa hacia sobreestimar o subestimar los valores observados.

El error promedio en la estimación de la concentración de clorofila-a es de 0.281, lo que significa que los valores predichos de concentración de clorofila-a se debían en promedio 0.281 unidades respecto a los valores reales.

El coeficiente NSE determina la magnitud relativa de la varianza residual en comparación con la varianza de los datos medidos. Un valor de 0.743 es aceptable y sugiere que el modelo tiene una mejor capacidad para predecir los valores observados en comparación con el uso de la media de las observaciones.

El modelo parece tener una buena capacidad predictiva, ya que los valores predichos están alineados con los valores reales, como se puede observar en el gráfico “Valores predicho vs. Valor real” de la Figura N°13.

Los residuos no muestran patrones claros en los gráficos de “Residuos del modelo vs. Predicción” y “Residuos del modelo vs. Id” de la Figura N°13, lo cual sugiere la presencia de homocedasticidad, es decir, varianza constante en los errores a lo largo de las predicciones. Este es un indicio positivo de un buen ajuste del modelo.

La distribución de los residuos, representada en el histograma, muestra que estos se aproximan a una distribución normal. Sin embargo, el gráfico Q-Q (*Quantile-Quantile*) revela ligeras desviaciones en los extremos, lo que podría indicar la presencia de valores atípicos o una leve falta de normalidad en los residuos.

En resumen, el diagnóstico de residuos sugiere que el Modelo 1 está bien ajustado, con una capacidad predictiva aceptable y residuos que se comportan de manera aleatoria y cercana a la normalidad, aunque con algunas desviaciones leves en los extremos.

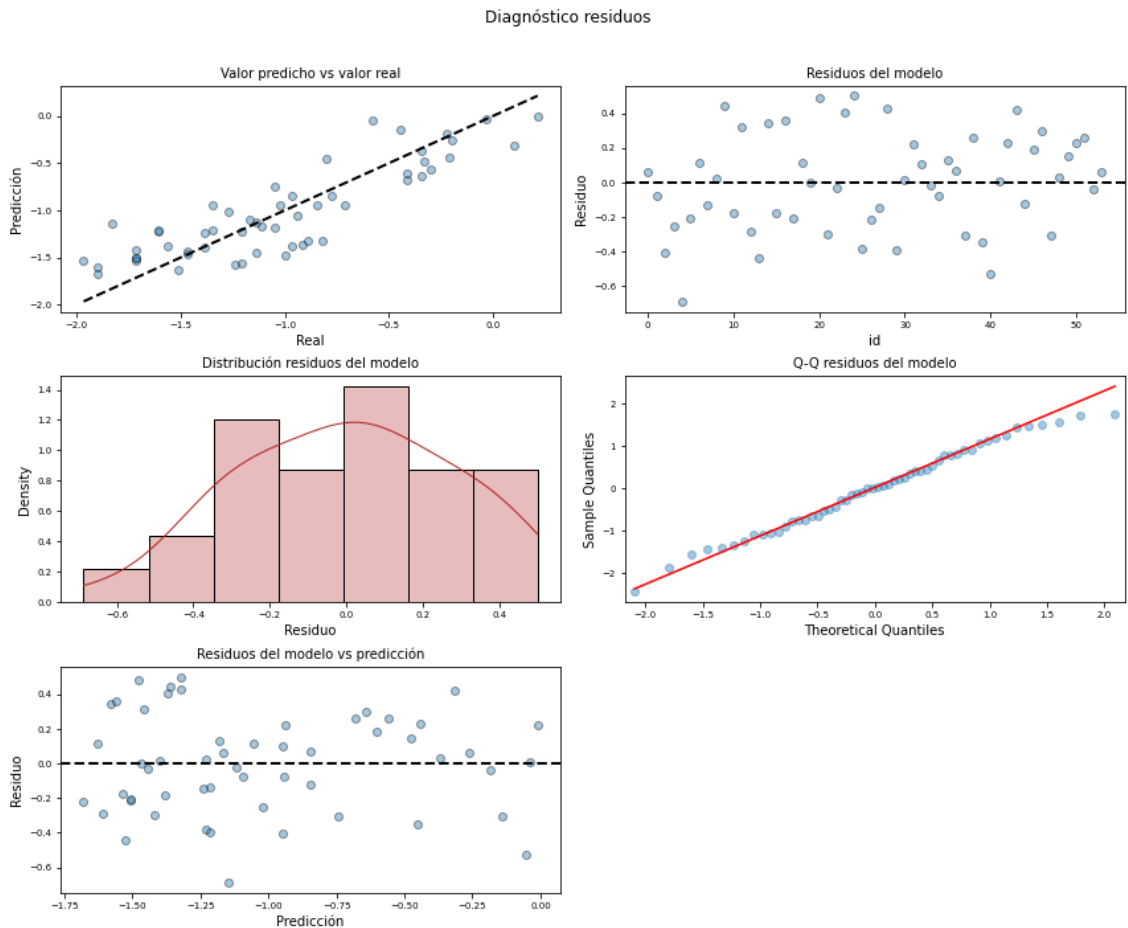


Figura N°13: Inspección Visual de los Residuos Modelo 1
Elaboración Propia a través de Spyder

Test de normalidad

Test Shapiro-Wilk: Estadístico = 0.983, p-value = 0.613

El valor del estadístico $W = 0.983$ indica que los datos se ajustan razonablemente bien a una distribución normal. Además, el valor-p de 0.613 es mayor que el umbral establecido de 0.05, lo que sugiere que no hay evidencia suficiente para rechazar la hipótesis nula de normalidad. Por lo tanto, según esta prueba, los residuos siguen una distribución normal, cumpliendo con este supuesto del modelo.

Test de Homocedasticidad

Prueba de Breusch-Pagan

Estadístico= 0.411, p-value = 0.745

Los resultados de esta prueba sugieren que no hay evidencia suficiente para rechazar la hipótesis nula de homocedasticidad, es decir, de que la varianza de los residuos es constante a lo largo de las observaciones. El valor-p de 0.745, siendo mayor que 0.05, indica que no se presenta heterocedasticidad en los residuos para este conjunto de datos, lo que implica que se cumple el supuesto de homocedasticidad en el modelo.

Multicolinealidad

Tabla N°6: Factor de Inflación de la varianza Modelo 1

Variable	VIF
B2	37.69
B4	34.14
B11	16.58

Los valores de VIF (Factore de inflación de la Varianza) obtenido para las variables del modelo indican un alta multicolinealidad. Un VIF mayor a 10 generalmente se considera indicativo de una fuerte correlación entre una variable predictora las demás. En este caso, los valores para las bandas presentes en la Tabla N°6 sugieren que estas variables están altamente correlacionadas con otras en el modelo. Esto puede causar inestabilidad en los coeficientes de regresión, haciendo que las estimaciones sean menos precisas y las interpretaciones de los efectos de cada variable sean menos confiables.

De la Figura N°10, que presenta la matriz de correlaciones, se observa que las bandas B2 y B4 están fuertemente relacionadas entre sí. Esto sugiere que incluir ambas en el modelo podría resultar redundante, ya que aportan información similar. Además, el factor de inflación de la varianza (VIF) confirma que los coeficientes de las bandas B2 y B4 son los más afectados por la alta correlación con otras variables predictoras del modelo.

Aplicación del Modelo 1

Al aplicar la función inversa a la Ecuación 1 y aplicar el modelo a los valores de reflectancia de las bandas para cada píxel de la imagen Sentinel del lago Llanquihue correspondiente a la fecha 07/02/2021, se obtiene la estimación de la concentración de clorofila-a, representada en la Figura N°14. En el mapa principal se observa la distribución general de la clorofila-a en el lago, mientras que los paneles de la derecha muestran un *zoom* de las estaciones de muestreo. La concentración de clorofila-a, representada en una escala de colores de 0 a 1 mg/m³, indica variaciones en los niveles de clorofila-a en el lago. Los colores verdes y amarillos representan concentraciones más altas en comparación con los azules, que indican concentraciones más bajas. En este caso, parece que la mayor parte del lago muestra concentraciones relativamente bajas, con valores en torno a 0 mg/m³ a 0.4 mg/m³, aunque algunas áreas cercanas a la costa podrían tener ligeras elevaciones en la concentración. Sin embargo, estas áreas pueden estar representando zonas de tierra debido a que el *shape* no calza perfecto con el lago.

Se estimaron además las concentraciones de clorofila-a para las imágenes disponibles en los meses de verano e invierno, para observar la variación de este parámetro en la serie temporal. Los mapas de los meses de noviembre, diciembre, enero y febrero representados en la Figura N°15 muestran concentraciones de clorofila-a bajas. Además, se observa una distribución homogénea en todo el lago sin grandes diferencias.

Los mapas correspondientes a los meses de mayo, junio, agosto y septiembre presentan concentraciones de clorofila-a más altas, especialmente en junio. Además, la variabilidad espacial es mayor, con algunas áreas con concentraciones más altas que otras.

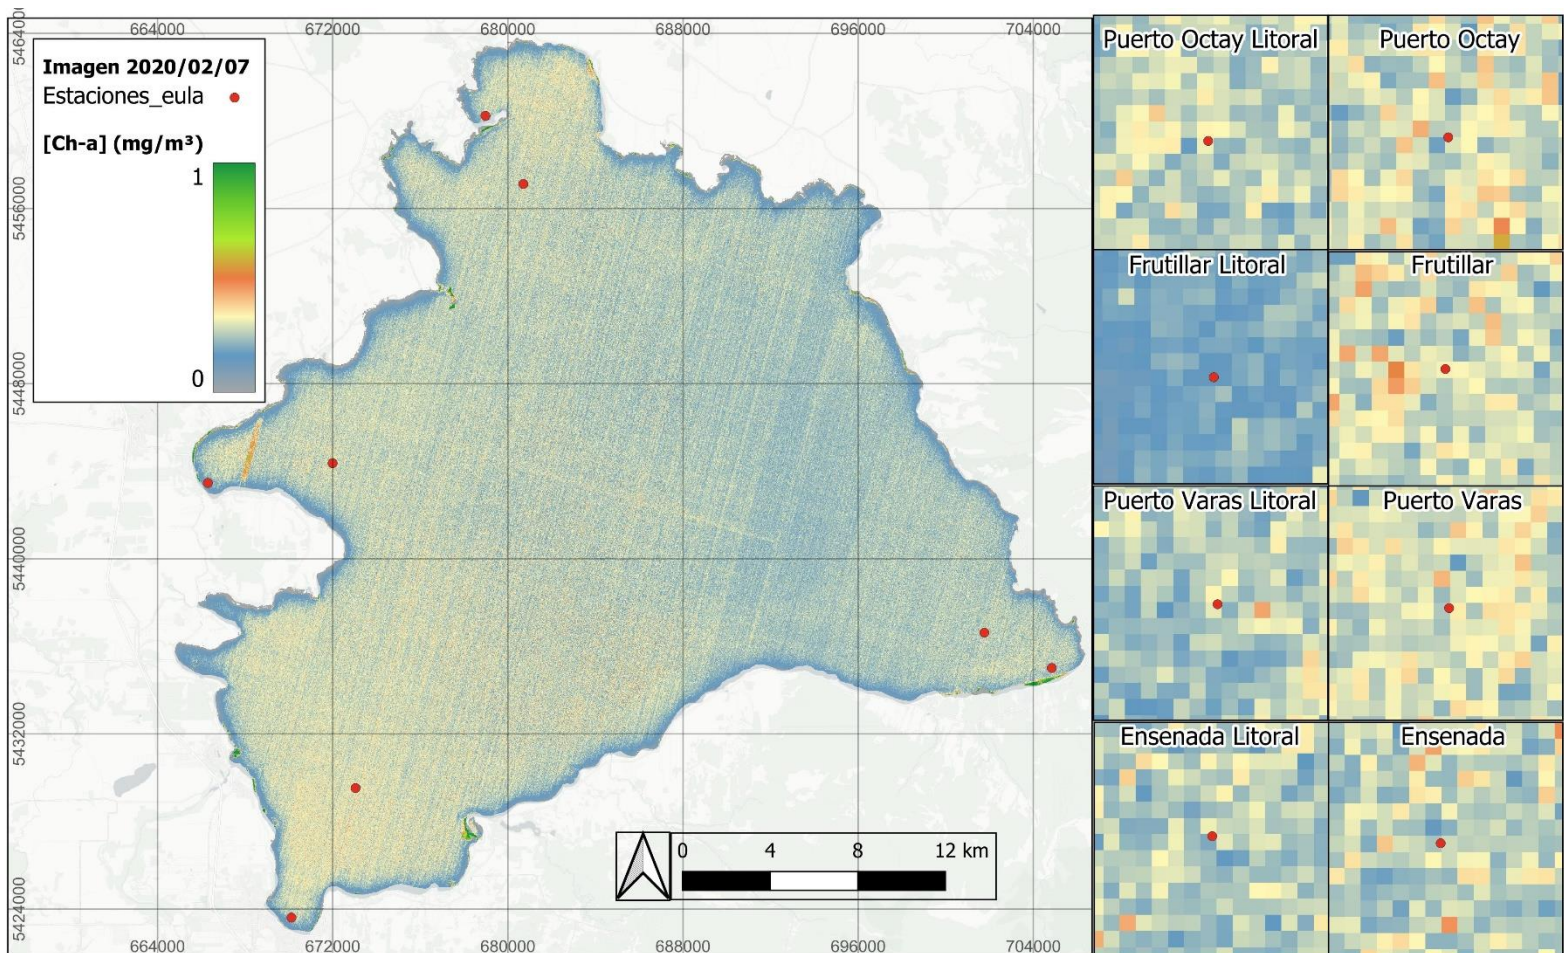


Figura N°14: Predicción de la concentración de clorofila-a aplicando el Modelo 1 la imagen del 07/02/2021.

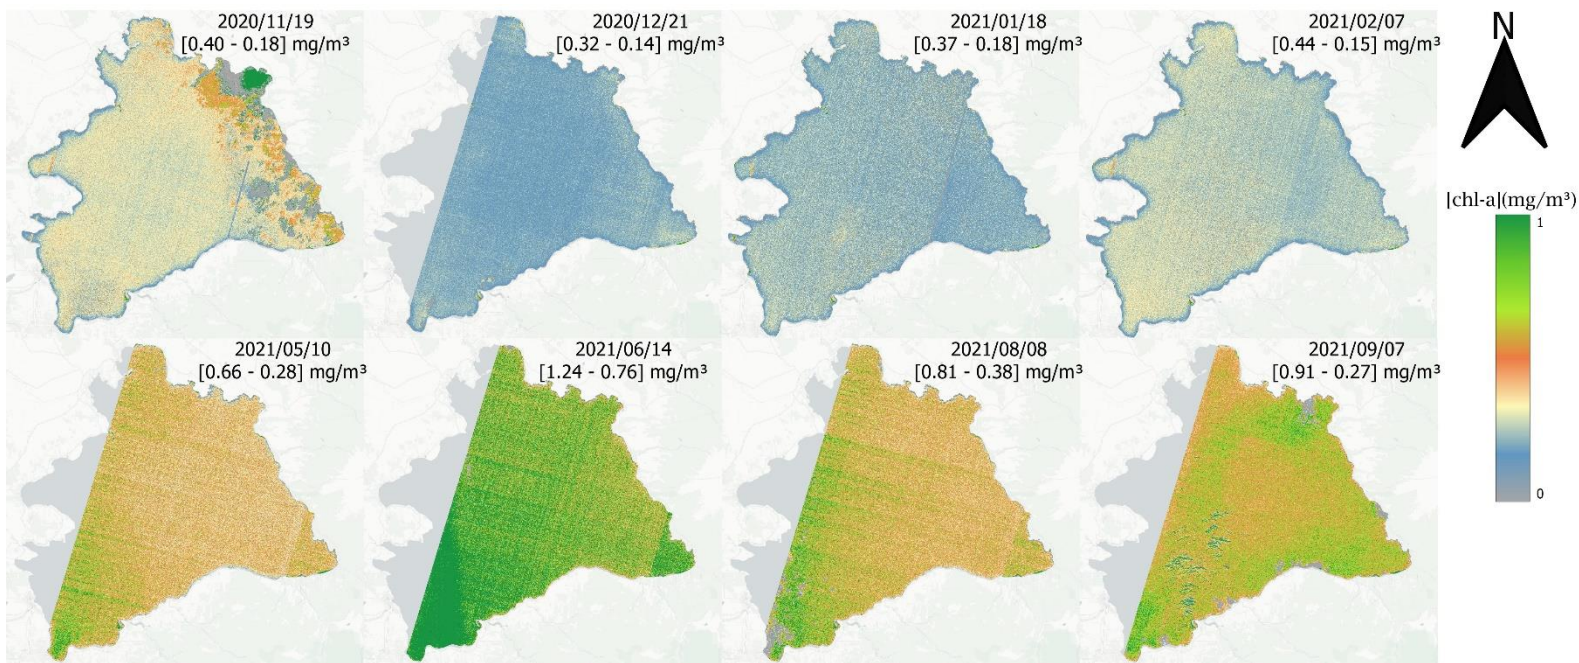


Figura N°15: Predicción [Chl-a] para los periodos verano (superior) e invierno (inferior). Las concentraciones indicadas corresponden el intervalo de valores del muestreo in-situ para la fecha correspondiente.

5.2.2.- Modelo 2

Dado los resultados obtenidos en el ajuste anterior, se decidió eliminar la banda B2 del modelo debido a su alta correlación con otras bandas y su elevado factor de inflación de la varianza (VIF), lo cual indicaba redundancia en la información que aportaba. A continuación, se ajustó el modelo nuevamente, excluyendo esta variable, con el objetivo de reducir la multicolinealidad y mejorar la estabilidad de los coeficientes de las variables predictoras restantes.

Tabla N°7: Coeficientes del Modelo 2

Variable	Coeficiente	Valor p
Intercepto	-3.26	0.0
B4	0.0097	0.0
B11	-0.0104	0.0

resultando la siguiente ecuación:

$$\ln([ch - a]) = -3.26 + (B4 * 0.0097) + (B11 * -0.0104) \quad \text{Ec.2}$$

Tabla N°8: Medidas de Bondad de ajuste Modelo 2

Estadístico	Valor
R^2	0.621
$R^2_{ajustado}$	0.606
PBIAS	2.24e-13
RMSE	0.341
NSE	0.620

Del ajuste del modelo se observa que este es capaz de estimar el 62.1% de la variabilidad de la concentración de clorofila-a, mientras que el coeficiente de determinación ajustado indica que puede explicar el 60.6% de la variabilidad de este parámetro. Asimismo, el PBIAS sugiere que las estimaciones del modelo tienden a ser ligeramente superiores a las observaciones.

La cantidad de error en la estimación de la concentración de clorofila para este modelo es de 0.341, lo que significa que, en promedio, los valores predichos de concentración de clorofila se desvían en 0.341 de los valores reales. Por otro lado, un NSE de 0.62 sugiere que el modelo es un predictor mejor que la media de las observaciones, aunque podría considerarse levemente aceptable con un valor ideal de 1.

Al igual que el modelo anterior, el Modelo 2 muestra una buena capacidad predictiva, ya que los valores predichos se alinean de manera adecuada con los valores reales, lo que indica un buen ajuste.

En cuanto al análisis de los residuos, idealmente deberían seguir una distribución normal. En la gráfica de distribución de los residuos presente en la Figura N°16, estos parecen aproximarse a una distribución normal, aunque se observan algunas desviaciones. Esta observación se confirma en el gráfico Q-Q de los residuos, donde la mayoría de los puntos se alinean con la línea de la distribución normal, aunque se observan algunas desviaciones en los extremos. Estas desviaciones pueden ser indicativas de valores atípicos o una posible falta de normalidad en las colas de la distribución de los residuos.

La gráfica de “residuos vs. Predicción” de la Figura N°16, no muestra patrones claros, lo cual sugiere que se cumple el supuesto de homocedasticidad, es decir, la varianza de los residuos parece ser constante a lo largo de los valores predichos.

En resumen, el diagnóstico de residuos para el Modelo 2 sugiere un ajuste adecuado, con residuos distribuidos de manera normal y sin indicios de heterocedasticidad, lo cual lo hace adecuado para realizar predicciones dentro del rango de datos analizados.

Diagnóstico residuos

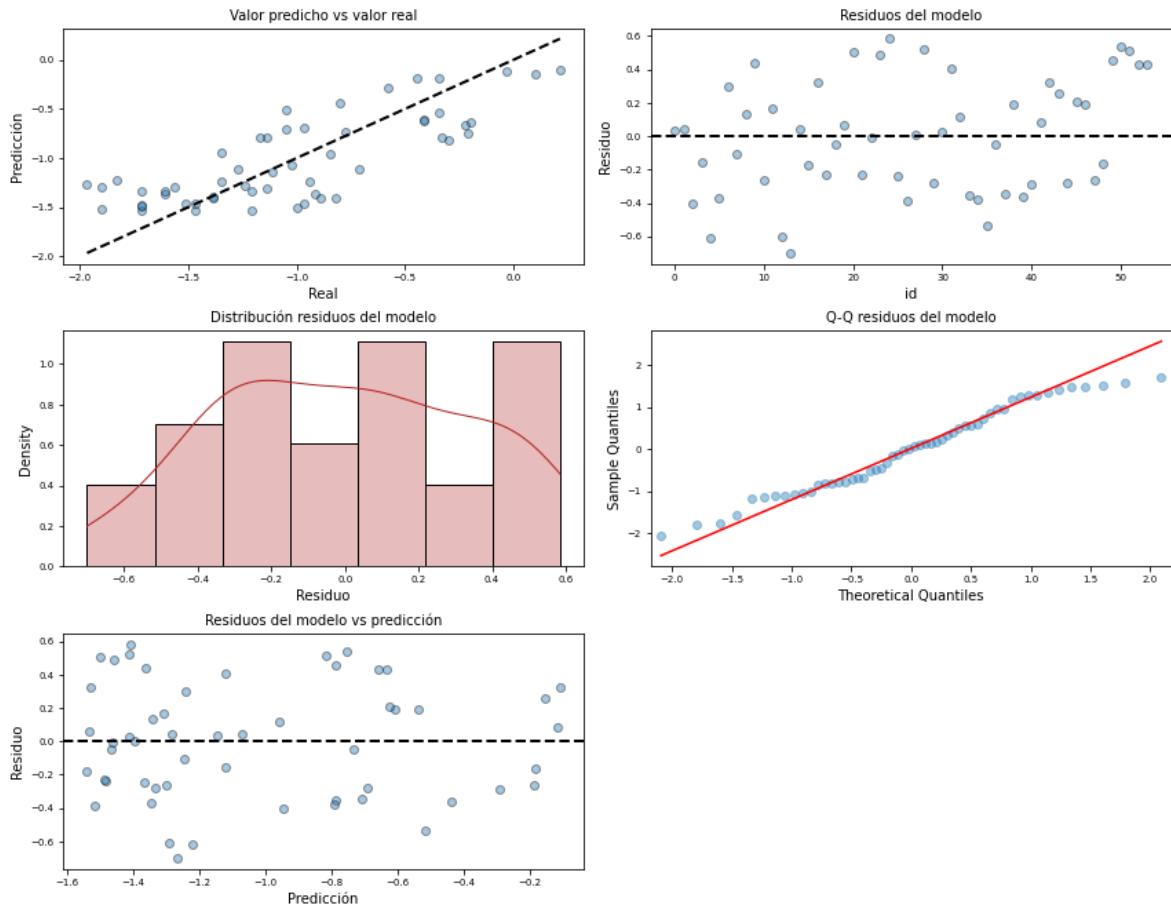


Figura N°16: Inspección Visual de los Residuos Modelo 2
Elaboración Propia a través de Spyder

Test de Normalidad

Test Shapiro-Wilk: estadístico = 0.982, p-value = 0.613

El estadístico $W = 0.982$ sugiere que los residuos se ajustan bien a una distribución normal. El valor-p de 0.613 es superior al nivel de significancia comúnmente utilizado (por ejemplo, 0.05), lo que indica que no hay evidencia suficiente para rechazar la hipótesis nula de normalidad, por lo tanto, se puede considerar que los residuos siguen una distribución normal.

Test de Homocedasticidad

Test Breusch-Pagan: Estadístico= 0.528, p-value = 0.592

Los resultados de esta prueba sugieren que no hay evidencia suficiente para rechazar la hipótesis nula de homocedasticidad, es decir, de que la varianza de los residuos es constante a lo largo de las observaciones. En este caso, el valor-p de 0.592, es mayor que 0.05, lo que indica que no hay presencia de heterocedasticidad en los residuos para este conjunto de datos.

Multicolinealidad

Tabla N°9: Factor de inflación de varianza Modelo 2

Variables	VIF
B4	1.08
B11	1.08

Los valores de VIF obtenidos para este modelo sugieren que prácticamente no existe correlación entre las variables predictoras. Los valores de VIF de 1.08 para las bandas B4 y B11 indican que no hay problemas de multicolinealidad en el modelo, lo cual es un indicador de que los coeficientes de regresión no están inflados y son estables, aumentando la confianza en los resultados del modelo.

Aplicación del Modelo 2

En comparación con el Modelo 1 la estimación de clorofila-a utilizando el Modelo 2 tiende a ser menor. Además, la distribución es más homogénea en los mapas de la Figura N°17 y 18. Sin embargo se mantiene la diferencia entre los meses de invierno y verano, siendo más heterogéneas y mayores las concentraciones en los meses de invierno.

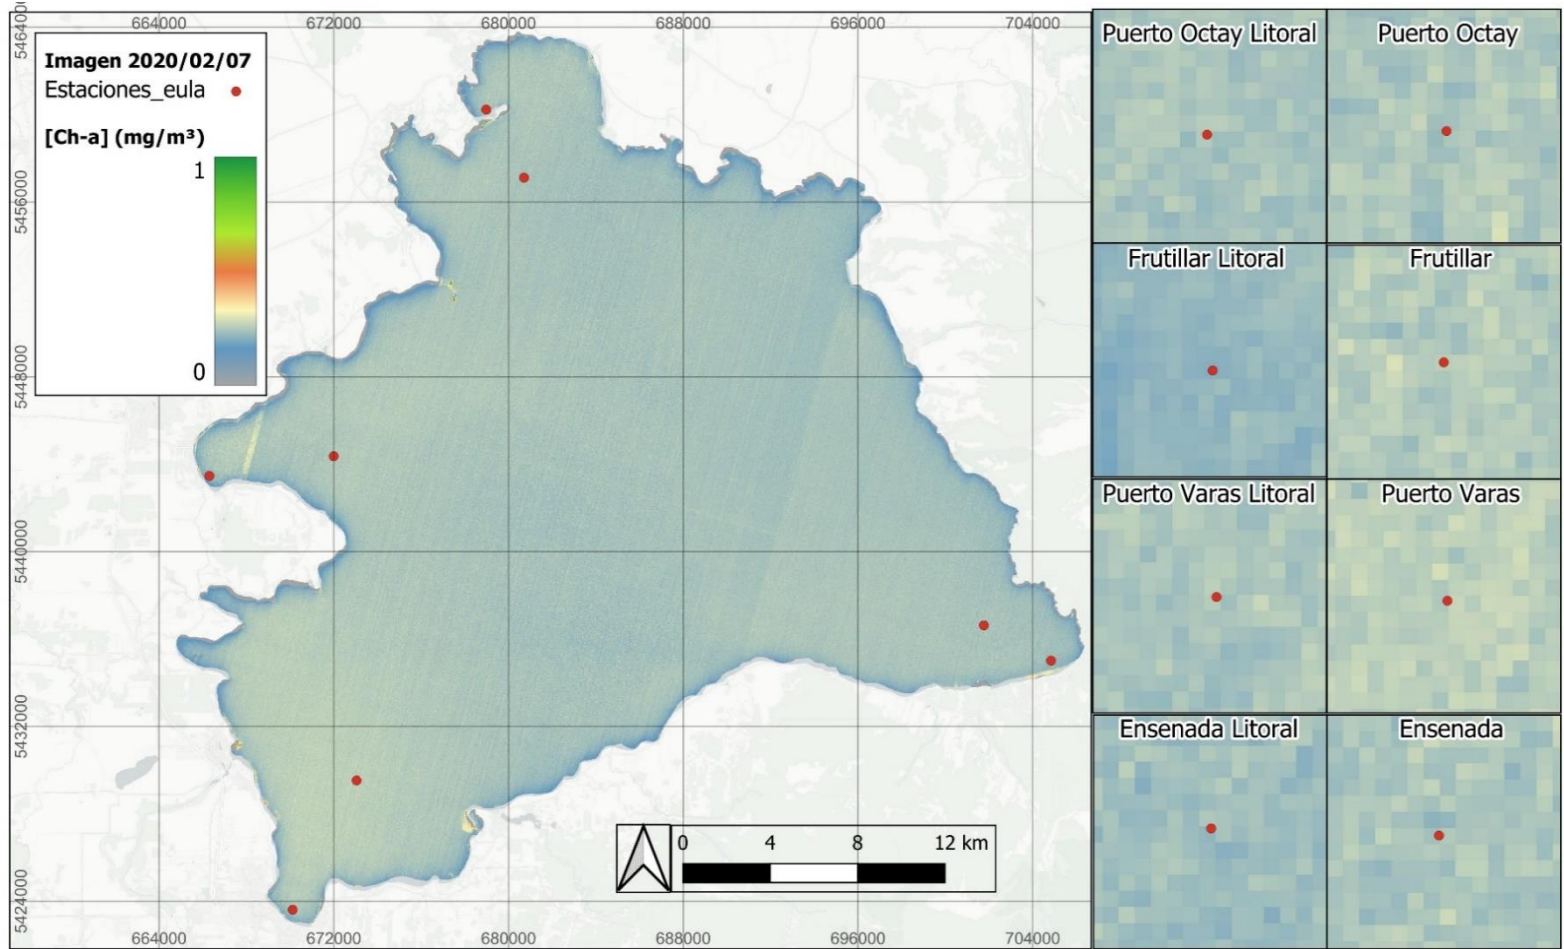


Figura N°17: Mapa de predicción de Concentración de clorofila aplicando el modelo 2 a la imagen Sentinel del 07/02/2021

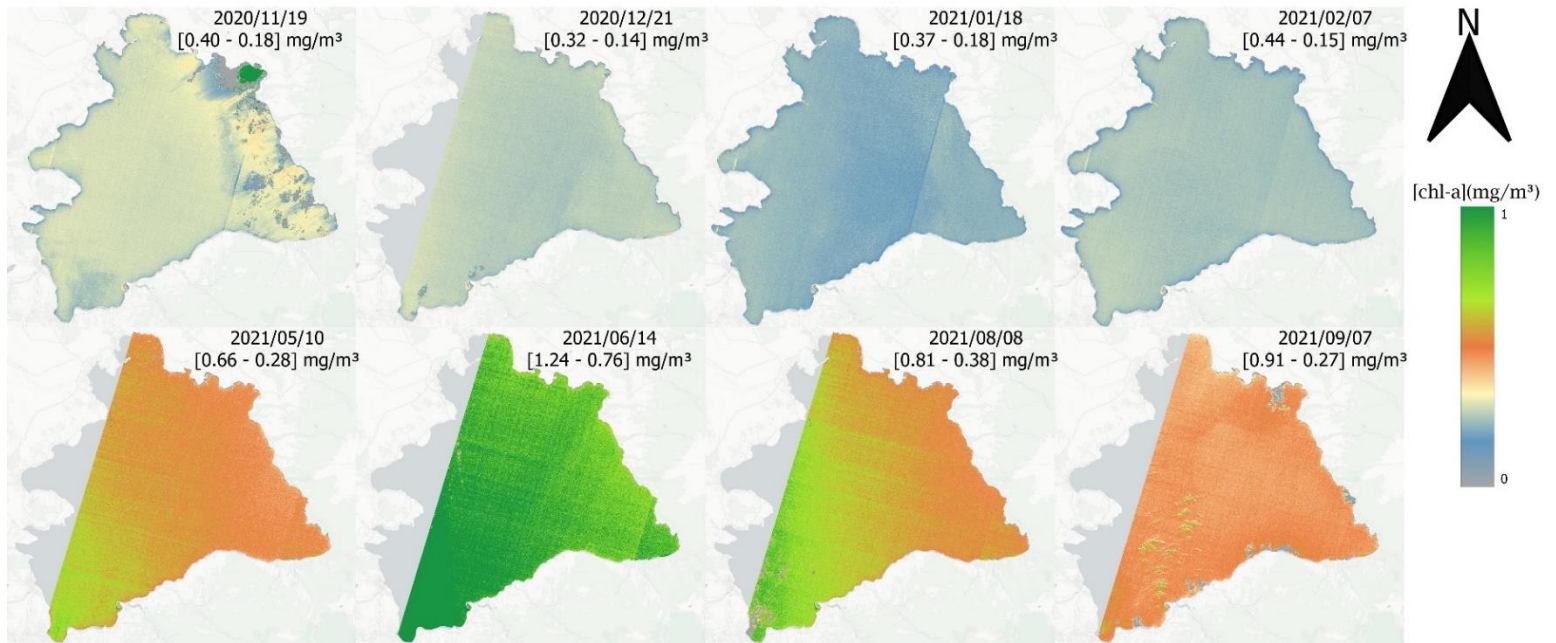


Figura N°18: Predicción [Chl-a] para los periodos verano (superior) e invierno (inferior). Las concentraciones indicadas corresponden el intervalo de valores del muestreo in-situ para la fecha correspondiente.

6.-Discusión

De las métricas obtenidas en los ajustes de los modelos mostrados en la Tabla N°10, se observa que al eliminar la banda 2, tanto el coeficiente de determinación R^2 como el coeficiente de determinación ajustado $R^2_{ajustado}$ disminuyen, al igual que el índice NSE. Esto indica una reducción en la capacidad predictiva del modelo sin la banda 2. Además, el error cuadrático medio (RMSE) aumenta al eliminar esta banda, lo cual refuerza la conclusión de que el ajuste del modelo es menos preciso. En cuanto al PBIAS, los valores obtenidos son prácticamente nulos, lo que sugiere que el modelo no presenta sesgo en sus predicciones y mantiene una buena capacidad para predecir valores observados. Sin embargo, este bajo valor de PBIAS podría también indicar un posible sobreajuste, dado el tamaño de la muestra disponible (54 observaciones).

En cuanto a la relevancia de las bandas seleccionadas, se destaca la presencia de las bandas 2 y 4 en el primer modelo. Estas bandas tienen una relación con la actividad óptica del pigmento clorofila-a, ya que presentan zonas del espectro electromagnético donde dicho pigmento muestra una mayor absorción. No obstante, dado que estas bandas están altamente correlacionadas entre sí, el aporte específico de cada una al modelo es ambiguo, lo cual dificulta la interpretación de sus coeficientes. Por su parte, aunque la banda 11 no tiene una relación óptica directa con la clorofila-a, sí parece contribuir numéricamente de manera significativa en el modelo.

Al aplicar la función exponencial resultando como se muestra en la Tabla N°11, la concentración estimada de clorofila-a responde exponencialmente a cambios en cada banda. Así, un aumento en la reflectancia de la banda 4 (rojo) incrementa la concentración de clorofila-a, mientras que un aumento en las bandas 2 (azul) y 11 (SWIR) la reduce. Esto resalta cómo los cambios en reflectancia tienen un efecto más pronunciado en la estimación del parámetro.

Los ráster generados mediante la aplicación de ambos modelos indican que, para el parámetro de clorofila-a, el lago presenta un estado oligotrófico para la superficie según los índices de Carlson y de Burns ya que no supera concentraciones de 2 mg/m^3 . En cuanto a la estimación de la concentración de clorofila-a en los periodos de verano e invierno representados en las Figuras N°15 y N°18 para los respectivos modelos, se observa que las concentraciones estimadas son menores en verano en comparación con el invierno, lo cual en primera instancia resulta contraintuitivo ya que en verano hay condiciones favorables de luz y temperatura que promueven el crecimiento del fitoplancton. Sin embargo, este patrón es consistente con los datos de muestreo y refleja una relación entre las variaciones de clorofila-a estimadas mediante imágenes satelitales y el fenómeno de estratificación térmica, documentado por la DGA en el lago Llanquihue. Durante el verano, el lago presenta una condición de estratificación térmica, mientras que en invierno y primavera ocurre una mezcla de la columna de agua lo cual dispone de una mayor cantidad de nutrientes a las aguas superficiales. Este fenómeno tiene un impacto directo en las concentraciones de clorofila-a observadas y se refleja en las estimaciones del modelo, lo cual explica las mayores concentraciones estimadas en invierno en la superficie del lago.

Finalmente, cabe señalar que las relaciones obtenidas con las bandas en este estudio no coinciden con las observadas en otros trabajos que correlacionan las concentraciones de clorofila-a, donde se espera que las bandas azules, verde y del borde rojo tengan mayor influencia. Esto podría explicarse en parte por las bajas concentraciones de clorofila-a en el lago, que limitan la caracterización óptica del agua. Además, la estratificación térmica estacional afecta la actividad fotosintética en la superficie, lo cual podría alterar la detección de la clorofila-a mediante el sensor MSI de Sentinel-2 (Perrone et al., 2021).

Tabla N°10: Bondad de ajuste de los Modelos

Modelo	R^2	$R^2_{Ajustado}$	RMSE	PBIAS	NSE
1	0.743	0.727	0.281	-1.37e-12	0.743
2	0.621	0.606	0.341	2.24e-14	0.62

Tabla N°11: Ecuaciones de Regresión

Modelo	Ecuación
1	$Ln([chl - a]) = -0.453 + (B2 * -0.0122) + (B4 * 0.041) + (B11 * -0.0316)$
1 exp	$[Chl - a] = e^{0.453+(B2*-0.0122) + (B4*0.041)+(B11*-0.0316)}$
2	$Ln([chl - a]) = -3.26 + (B4 * 0.0097) + (B11 * -0.0104)$
2 exp	$[Chl - a] = e^{-3.26+(B4*0.0097)+(B11*-0.0104)}$

7.- Conclusiones

El presente estudio tuvo como objetivo principal evaluar las correlaciones entre los datos de muestreo del Lago Llanquihue y los datos del sensor MSI de Sentinel-2 durante el periodo de muestreo 2020-2021. A partir de los datos obtenidos de Sentinel-2, fue posible generar modelos significativos de buen desempeño para estimar la concentración de clorofila-a mediante técnicas de teledetección.

En primer lugar, se logró construir una base de datos con imágenes del sensor MSI de Sentinel-2, tomadas en fechas cercanas al muestreo in situ (con una diferencia máxima de tres días). Utilizando estos datos, se cumplió con el objetivo de analizar la relación entre las variables. Aplicando técnicas estadísticas al conjunto de datos, se observó la existencia de correlaciones significativas entre ciertas bandas espectrales y la concentración de clorofila-a.

Los resultados obtenidos demostraron cinco correlaciones significativas entre las bandas de Sentinel-2 y la concentración de clorofila-a, lo que sugiere que estas bandas podrían ser utilizadas como indicadores para estimar este parámetro en el lago. Sin embargo, es importante tener en cuenta la alta colinealidad presente entre algunas de las bandas.

Se logró generar modelos de regresión lineal múltiple que cumplen con los supuestos del modelo utilizado, y su aplicación mostró que las estimaciones de clorofila-a son coherentes con los cambios observados en la superficie del lago a lo largo del año, incluyendo el efecto de la estratificación térmica en las concentraciones de clorofila-a. Además, las estimaciones sugieren que el lago mantiene un estado oligotrófico según los indicadores de Smith y Burns.

Este estudio enfrentó limitaciones, principalmente en la disponibilidad temporal de los datos satelitales debido a la nubosidad en las imágenes y el hecho de que 8 de las imágenes no abarcan la totalidad del lago. Asimismo, se utilizaron

imágenes sin corrección atmosférica (TOA), lo cual podría haber afectado la precisión del modelo propuesto.

Se recomienda ampliar la cobertura temporal de los datos y el tamaño de la muestra, además de considerar la estacionalidad del lago. También es relevante evaluar el efecto de la atmósfera en las bandas del satélite, comparando los resultados obtenidos con distintas correcciones atmosféricas.

Finalmente, los resultados de este estudio reflejan la importancia de continuar investigando en esta área, ya que la teledetección proporciona una potencial herramienta para la toma de decisiones en la gestión y conservación de los recursos hídricos.

8.- Bibliografía

- Abbas, M., & Alameddine, I. (2023). Predicting water quality variability in a Mediterranean hypereutrophic monomictic reservoir using Sentinel 2 MSI: the importance of considering model functional form. *Environmental Monitoring and Assessment*, 195(8). <https://doi.org/10.1007/s10661-023-11456-7>
- Amat Rodrigo, J. (2024). *cienciadedatos.net*. Zenodo. <https://doi.org/10.5281/ZENODO.10006329>
- Ansari, A. A., Gill, S. S., Lanza, G. R., & Rast, E. W. (2011). *Eutrophication: Causes, Consequences and Control*. Springer. <https://doi.org/DOI10.1007/978-90-481-9625-8>
- Barraza-Moraga, F., Alcayaga, H., Pizarro, A., Feléz-Bernal, J., & Urrutia, R. (2022). Estimation of Chlorophyll-a Concentrations in Lanalhue Lake Using Sentinel-2 MSI Satellite Images. *Remote sensing*, 14(22), 5647.
- Chuvieco, E. (2010). *Teledetección Ambiental: La observación de la Tierra desde el espacio*. Ariel.
- DGA. (2014). *DIAGNÓSTICO DE LA CONDICIÓN TRÓFICA DE CUERPOS LACUSTRES UTILIZANDO NUEVAS HERRAMIENTAS TECNOLÓGICAS*. <https://snia.mop.gob.cl/sad/LGO5517.pdf>
- DGA. (2022). *LEVANTAMIENTO DE INFORMACIÓN LIMNOLÓGICA COMO ANTECEDENTES PARA LA PROPUESTA DE NSCA DE LAGOS NORPATAGÓNICOS*.
- DGA (2021). *EVALUACIÓN DE LA CONDICIÓN TRÓFICA EN CUERPOS LACUSTRES MONITOREADOS POR DGA*.
- European Space Agency. (s. f.). *Sentinel-2 Mission*. sentiwiki.copernicus.eu. <https://sentiwiki.copernicus.eu/web/s2-mission>

- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Huovinen, P., Ramírez, J., Caputo, L., & Gómez, I. (2019). Mapping of spatial and temporal variation of water characteristics through satellite remote sensing in Lake Panguipulli, Chile. *The Science of the Total Environment*, 679, 196-208. <https://doi.org/10.1016/j.scitotenv.2019.04.367>
- Ivanda, A., Šerić, L., Bugarić, M., & Braović, M. (2021). Mapping chlorophyll-a concentrations in the Kaštela Bay and Brač Channel using ridge regression and Sentinel-2 satellite images. *Electronics*, 10(23), 3004. <https://doi.org/10.3390/electronics10233004>
- Jang, W., Kim, J., Kim, J. H., Shin, J.-K., Chon, K., Kang, E. T., Park, Y., & Kim, S. (2024). Evaluation of Sentinel-2 based chlorophyll-a estimation in a small-scale reservoir: Assessing accuracy and availability. *Remote Sensing*, 16(2), 315. <https://doi.org/10.3390/rs16020315>
- Abarca Mesa, J. (2018). *Modelación Hidrodinámica del Lago Llanquihue*. Universidad de Chile.
- Ministerio Secretaría General de La Presidencia. (2010). *ESTABLECE NORMAS SECUNDARIAS DE CALIDAD AMBIENTAL PARA LA PROTECCIÓN DE LAS AGUAS DEL LAGO LLANQUIHUE*. Biblioteca del Congreso Nacional de Chile.
- Mobley, C. D., Stramski, D., Paul Bissett, W., & Boss, E. (2003). Optical Modeling of Ocean Water. Is the Case-I and Case II still useful? *Journal of the Oceanography Society*, 17(2), 8. https://tos.org/oceanography/assets/docs/17-2_mobley.pdf
- Molkov, A. A., Fedorov, S. V., Pelevin, V. V., & Korchemkina, E. N. (2019). Regional Models for High-Resolution Retrieval of Chlorophyll a and TSM

Concentrations in the Gorky Reservoir by Sentinel-2 Imagery. *Remote Sensing*, 11(1215). <https://doi.org/10.3390/rs11101215>

- Moses, W. J., Gitelson, A. A., Berdnikov, S., & Povazhnyy, V. (2009). Estimation of chlorophyll-a concentration in case II waters using MODIS and MERIS data—successes and challenges. *Environmental Research Letter*, 4(4). <https://doi.org/10.1088/1748-9326/4/4/045005>
- Palmer, S. C. J., Kutser, T., & Hunter, P. D. (2015). Remote sensing of inland waters: Challenges, progress and future directions. *Remote Sensing of Environment*, 157, 1-8. <https://doi.org/10.1016/j.rse.2014.09.021>
- Perrone, M., Scalici, M., Conti, L., Moravec, D., Kropáček, J., Sighicelli, M., Lecce, F., & Malavasi, M. (2021). Water mixing conditions influence Sentinel-2 monitoring of chlorophyll content in monomictic lakes. *Remote Sensing*, 13(14), 2699. <https://doi.org/10.3390/rs13142699>
- Pozo, J. C. M. (2008). *LA EUTROFIZACIÓN DE LOS LAGOS Y SUS CONSECUENCIAS* [Universidad Tecnica del Norte]. <http://repositorio.utn.edu.ec/bitstream/123456789/720/2/06%20NUT%2099%20TESIS.pdf>
- Seabold, S., & Perktold, J. (2010). *Statsmodels: Econometric and Statistical Modeling with Python*. Proceedings of the 9th Python in Science Conference.
- Sobrino, R. (2014). *APLICACIÓN DE LA TELEDETECCIÓN Y MODELOS DE REGRESIÓN EN LA CARACTERIZACIÓN DEL LAGO DE SANABRIA* [UNED]. http://e-spacio.uned.es/fez/eserv/bibliuned:grado-Ciencias-CAmb-Rsobrino/Sobrino_Navas_Raquel_TFG.pdf
- Solórzano, J., & Perilla, G. (2022). *Como Usar Google Earth Engine y no fallar en el intento* (1.^a ed.). <https://doi.org/10.22201/ciga.9786073066969e.2022>

- Toming, K., Kutser, T., Laas, A., Sepp, M., Paavel, B., & Nõges, T. (2016). First Experiences in Mapping Lake Water Quality Parameters with Sentinel-2 MSI Imagery. *Remote Sens*, 8(640). <https://doi.org/10.3390/rs8080640>
- Universidad de Murcia. (2003). *Interacción de la Radiación con lo Objetos*. SIGMUR. Recuperado 11 de abril de 2023, de <https://www.um.es/geograf/sigmur/teledet/tema02.pdf>
- Wu, M., Zhang, W., Wang, X., & Luo, D. (2008). Application of MODIS satellite data in monitoring water quality parameters of Chaohu Lake in China. *Environ Monit Assess*, 148, 255-264.

8.- Anexos

Imágenes Satelitales Sentinel-2 de la serie de tiempo (15/10/2020 – 09/07/2021) y sus respectivos mapas de concentración de clorofila-a aplicando el modelo 2

