



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

**Monitoreo de la calidad del agua de
cuerpos lénticos mediante redes
neuronales artificiales y sensores
remotos**

TESIS

Que para obtener el título de

Ingeniera Civil

P R E S E N T A

María Fernanda Martínez Arciga

DIRECTOR DE TESIS

M.I. Rodrigo Takashi Sepúlveda Hirose



Ciudad Universitaria, Cd. Mx., 2024

Agradecimientos

Agradezco a la Universidad Nacional Autónoma de México por permitirme ser parte de esta gran institución, por brindarme la formación necesaria para mi desarrollo profesional y ponerme en el camino a personas maravillosas.

A la Secretaría de Educación, Ciencia, Tecnología e Innovación por el apoyo brindado durante mi participación en el proyecto 201/2021 *“Oportunidades en el uso de imágenes satelitales en la solución de las necesidades de la CDMX”*, el cual hizo posible la realización de esta tesis.

Agradezco a todos mis profesores de la facultad, en especial al Maestro Rodrigo Sepúlveda por ayudarme a realizar este trabajo y por ser un gran ejemplo como profesional y ser humano.

Agradezco también a mis amigos, por ser un refugio en momentos difíciles y por tantos momentos de alegría. Su amistad ha sido fundamental para mi bienestar y éxito.

Y, por último, agradezco a mi madre y a mi hermana, por ser mi sustento y por tenerme tanta paciencia. Esto es por y para ustedes.

ÍNDICE

Introducción.....	1
1 Marco teórico.....	4
1.1 El uso de la percepción remota en el monitoreo de la calidad del agua.....	4
1.2 Tipos de percepción remota.....	7
1.3 Interacciones de la atmósfera con la radiación electromagnética.....	8
1.4 La materia y la radiación electromagnética.....	8
1.5 Imágenes satelitales.....	10
1.6 Satélites.....	13
2 Estado del arte.....	15
Objetivo.....	20
3 Metodología.....	20
3.1 Reconocimiento del sitio de interés.....	20
3.1.1 Clima.....	21
3.1.2 Orografía.....	22
3.1.3 Vegetación.....	22
3.1.4 Hidrología.....	23
3.1.5 Capacidad del embalse.....	24
3.1.6 Uso del recurso hídrico.....	24
3.2 Problemática.....	26
3.3 Índice de estado trófico a partir de la profundidad del Disco Secchi.....	28
3.4 Recopilación de datos.....	31
3.5 Modelos.....	40
3.5.1 Análisis de correlación.....	40
3.5.2 Redes neuronales.....	43
3.6 Calibración y entrenamiento de los modelos.....	45
3.6.1 Medidas de evaluación.....	45
4 Resultados.....	47
4.1 Arquitectura y desempeño.....	47
4.2 Interpretación de resultados.....	53
5 Conclusiones.....	56
Anexos.....	57
Bibliografía.....	62



Introducción

El agua es indispensable para el desarrollo de la vida, en México se establece en la constitución política como un derecho el acceso, la disposición y el saneamiento.

El derecho humano al agua es indispensable para vivir dignamente y es condición previa para la realización de otros derechos humanos (CNDH, 2014), con el fin de garantizarlo es indispensable enfocarse en las características del agua que recibe la población, por ello, el monitoreo de la calidad del agua resulta de vital importancia pues se realiza con la finalidad de conocer las fluctuaciones de parámetros físicos, químicos y biológicos, para así determinar si las características del agua son aptas para ser destinadas a diversos fines (recreación, potabilización o protección de los ecosistemas marinos).

Según informes, la Comisión Nacional del Agua (CONAGUA, 2021) reportó que por lo menos el 60.4% de los cuerpos de agua superficial se encuentra por encima de los límites aceptables de calidad del agua, analizando ocho indicadores: Demanda Bioquímica de Oxígeno a cinco días (DBO5), Demanda Química de Oxígeno (DQO), Sólidos Suspendidos Totales (SST), Coliformes Fecales (CF), Escherichia coli, (E_COLI), Enterococos (ENTEROC), Porcentaje de Saturación de Oxígeno (OD%) y Toxicidad (TOX).

Uno de los embalses más importantes para la Zona Metropolitana del Valle de México (en materia de abastecimiento de agua potable) es la presa Valle de Bravo, la cual históricamente ha mostrado cambios negativos en la calidad del agua, lo cual ha mermado y limitado los usos para los que anteriormente fue destinada.

El monitoreo tradicional en este embalse y en la mayor parte de los cuerpos de agua superficiales consiste en la recolección en sitio de una serie de muestras que buscan ciertos parámetros fisicoquímicos que determinen el estado general de los cuerpos de agua, sin embargo, estos suelen ser costosos y demandantes en cuanto a tiempo, por ello, resulta importante desarrollar métodos más prácticos que permitan dar un seguimiento continuo al estado del agua.



La percepción remota es una disciplina que permite analizar de manera rápida y económica datos físicos de la tierra obtenidos mediante sensores instalados en dispositivos remotos, como aviones, satélites y drones; esta disciplina es aplicable a la estimación de variables que generan un cambio en el espectro óptico, por ejemplo, la transparencia, el estado trófico, las partículas suspendidas totales y las variaciones de clorofila, tales variaciones indican problemas de contaminación más específicos.

En el presente trabajo se pretende analizar dichas variables para realizar estimaciones de las características del agua del embalse mencionado, y así generar una propuesta metodológica que correlacione mediciones de reflectancias con algunas de las variables de calidad.

En el capítulo 1 (Marco teórico), se describen las generalidades sobre los conceptos básicos de la percepción remota, por ejemplo, el uso que se le da dentro del monitoreo de la calidad del agua, la definición, los tipos de percepción remota existentes y cómo se lleva a cabo el funcionamiento de ésta a través del flujo de energía en forma de radiación electromagnética.

En el capítulo 2 (Estado del arte) se hace un breve resumen de la recopilación documental acerca de diversos trabajos de investigación que hicieron posible la elección y justificación de este trabajo.

En el capítulo 3 (Metodología), se describen las particularidades relevantes del embalse en estudio como la climatología, las características hidrológicas de la región, la vegetación, y la problemática ambiental que ha venido presentando el agua del embalse.

Finalmente, se describe el procedimiento para recopilar datos de calidad asociados a Valle de Bravo y a diversos cuerpos lénticos con características climatológicas similares dentro de la República Mexicana (obtenidos en su mayoría de los muestreos anuales reportados por CONAGUA y relacionados con valores de reflectancia extraídos de imágenes satelitales de Landsat 7 y 8).



Del mismo modo, se muestra el grado de correlación que poseen los parámetros de calidad del agua con los valores de reflectancia para el posterior desarrollo del algoritmo de aprendizaje.

Dentro del mismo capítulo se incluye información relevante como la definición y los usos que se le dan a los algoritmos de aprendizaje profundo o *Deep Learning* enfocado a los modelos de redes neuronales.

Finalmente, en el capítulo 4 se muestran los resultados del desempeño de los algoritmos, denotando las posibles implicaciones que dan origen a éstos.



1 Marco teórico

1.1 El uso de la percepción remota en el monitoreo de la calidad del agua

La percepción remota es una disciplina que permite obtener la información de un objeto a través de la obtención de datos y de información de la superficie terrestre a través de sensores remotos que obtienen datos de mediciones in situ, esto permite capturar, procesar y analizar imágenes utilizando la luz del espectro visible o invisible.

De manera general se puede afirmar que los sistemas de percepción remota constan de tres elementos fundamentales, una fuente de iluminación, un sensor y finalmente el objeto observado.

Esta disciplina comienza en EE. UU. en el periodo de 1946 a 1950 con el lanzamiento de los primeros cohetes V-2 adicionados con cámaras fotográficas que figuraban como sensores remotos, los cuales fueron el parteaguas a distintos proyectos y así surgieron las primeras capturas de imágenes de la superficie terrestre (CENAPRED, 2021).

En un principio las fotografías aéreas eran los productos más utilizados de la percepción remota porque se utilizaban como base para la elaboración de mapas cartográficos, sin embargo, gracias al desarrollo tecnológico, el procesamiento y la obtención de dichas imágenes se volvió más eficaz, para así convertirse en una opción económica y rápida de trabajar con grandes superficies (SEMAR, 2009).

La recolección de información se da a través de la colocación de sensores en aeronaves tripuladas como aviones y no tripulada como satélites, estos últimos sólo van en función de factores como su resolución espacial, el número de regiones espectrales o bandas que se registran, la periodicidad con la que obtienen las imágenes, etc.

Para que la percepción remota sea posible es necesario contar con algún tipo de interacción entre el objeto y el sensor creando un flujo de energía, un ejemplo de

ello es la capacidad que tenemos para visualizar objetos cuando nuestros ojos convierten convenientemente una energía luminosa procedente de los mismos.

En el caso de la percepción remota este flujo energético que se establece entre el sensor y el objeto se presenta en forma de radiación electromagnética. La imposibilidad física de separar la materia de la energía da lugar a la afirmación de que la interacción entre la materia y la radiación electromagnética dan lugar a la modificación de ésta (Villegas, 2008).

La radiación electromagnética se produce a través de campos eléctricos y magnéticos compuestos de cargas eléctricas en movimiento, las cuales originan oscilaciones perpendiculares; esta energía viaja por el espacio en forma de ondas electromagnéticas compuestas por crestas y valles, la distancia entre dos crestas o valles se denomina longitud de onda (λ), esta longitud diferencia al tipo de onda.

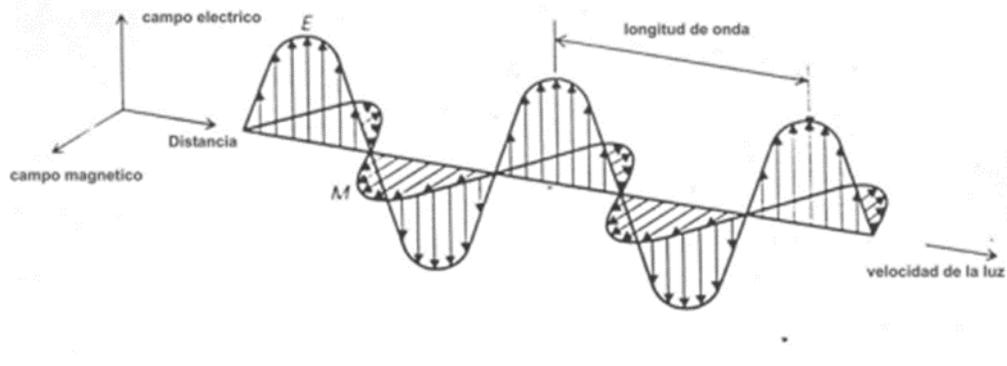


Figura 1.1. Onda electromagnética, introducción a la percepción remota y sus aplicaciones geológicas

Gracias a las propiedades físicas de la radiación electromagnética es posible describir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia y aunque los rangos de estos son continuos, se han establecido una serie de bandas o rangos de acuerdo con valores específicos; la organización de estas bandas permite describir el espectro electromagnético.

Este espectro a su vez se subdivide en algunos tipos más familiares de energía como lo son los rayos X, los rayos ultravioletas (UV), los rayos infrarrojos, las microondas y las ondas de radio, los cuales están categorizados por su posición o longitud de onda dentro del espectro, las cuales oscilan entre los 0.0001 micrómetros (μm) hasta los 100 metros, las más pequeñas corresponden a los rayos X y las más grandes a las ondas de radio.

El rango en el espectro electromagnético que interesa al campo de la percepción remota es conocido como el rango óptico y está comprendido en longitudes de onda entre 0.3 y 15 μm . El rango comprendido entre 0.38 μm y 3 μm , este rango se denomina como la parte reflejada porque la energía que captan los sensores es generada a partir de la reflexión de la energía solar de los objetos hacia la superficie; esta porción reflejada se divide en tres subregiones: visible, infrarrojo cercano e infrarrojo medio.

La porción que es captada por el ojo humano está comprendida entre 0.38 y 0.72 micrómetros de longitud de onda. Dentro de ella suelen distinguirse tres bandas, las cuales son: azul (0.35 μm a 0.5 μm), verde (0.5 μm a 0.6 μm) y rojo (0.6 μm a 0.72 μm). Por su parte el rango entre 0.72 μm y 1.3 μm es conocido como infrarrojo cercano, de 1.3 μm a 7 μm tenemos el infrarrojo medio y de 7 μm a 15 μm se encuentra el infrarrojo lejano, que a su vez es la región donde operan los sensores termales.

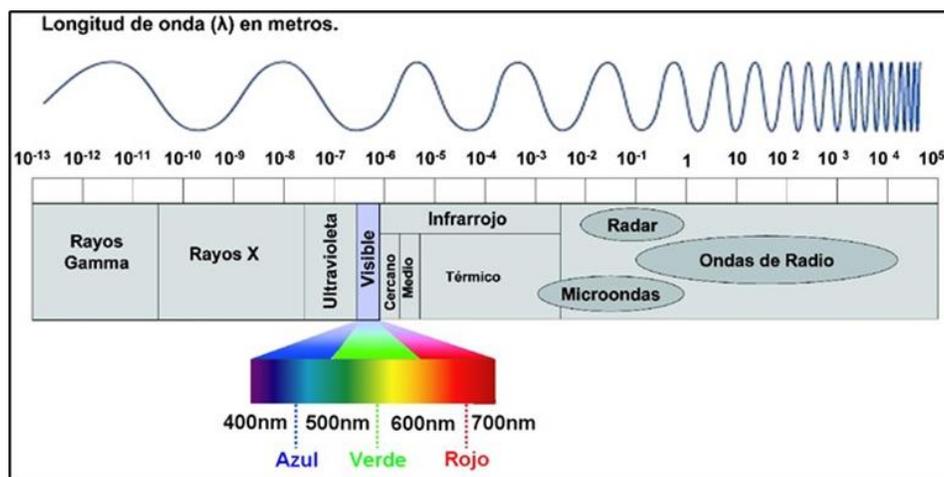


Figura 1.2 Espectro electromagnético. Fuente: http://uapas1.bunam.unam.mx/ciencias/efecto_doppler/



1.2 Tipos de percepción remota

La percepción remota puede clasificarse en:

- Satelital. Cuando se emplean plataformas satelitales equipadas con sensores que miden la radiación electromagnética en un sistema Atmósfera-Tierra.
- Fotografía y fotogrametría. Cuando las fotografías son utilizadas para capturar la luz en el rango visible.
- Termal. Cuando se usan las regiones térmicas del espectro electromagnético.
- Radar. Cuando se utilizan microondas.
- LiDAR. Cuando se emplea la emisión de pulsos láser.

Por otra parte, dependiendo de cómo es registrada y utilizada la energía, la percepción remota se divide en dos tipos de sistemas (Aguilar, 2000):

- Sistemas de percepción pasiva.

Estos sistemas generan una señal que rebota en el objeto y posteriormente mide la respuesta como energía reflejada, un ejemplo de ello son las ondas de radio captadas por los sensores RADAR, comúnmente son utilizadas para encontrar la distancia, dirección y forma de los objetos, además de no ser afectadas por factores climáticos.

- Sistemas de percepción activa.

Estos sistemas simplemente captan las señales emitidas naturalmente y reflejadas por los cuerpos percibidos, son generadas por la energía solar y poseen la capacidad de proveer una vasta información sobre los objetos percibidos.



1.3 Interacciones de la atmósfera con la radiación electromagnética

Para el caso de un sistema de percepción que capta radiación solar emitida y reflejada por la tierra, la energía debe ser captada por un sensor pasivo (adicionado a un satélite que funciona con radiación solar reflejada), pasar a través de la atmósfera y después regresar al sensor. Aunque la ruta puede parecer simple, existen muchos factores atmosféricos (vapor de agua, nitrógeno, oxígeno, dióxido de carbono y ozono) que interfieren interactuando mediante vibraciones y rotaciones que generan un efecto red que es capaz de absorber rangos específicos de longitud de onda (bandas), teóricamente se puede afirmar que los componentes atmosféricos pueden absorber hasta un 50% del espectro electromagnético, lo cual tiene como consecuencia que no toda la energía solar pueda incidir en el planeta (Villegas, 2008).

Lo anterior implica que las imágenes obtenidas a través de la percepción remota están inevitablemente degradadas en varias formas por los componentes de la atmósfera, por lo anterior solo hay un número limitado de bandas y combinaciones disponibles para los sistemas de detección.

Otra consideración para tomar en cuenta es la interacción de los elementos que componen la superficie terrestre (agua, suelo y vegetación), puesto que, para la percepción en cuerpos de agua, la presencia de vegetación o suelo en estos nos traería incongruencias.

1.4 La materia y la radiación electromagnética

Todos los objetos que tengan temperaturas por encima del cero absoluto (-273°C), emiten energía electromagnética o radiación, y la cantidad de la energía emitida o la longitud de onda es una función compleja de la temperatura y de la naturaleza de su composición (Villegas, 2008), por lo tanto, cualquier material tiene un espectro característico que depende de su constitución química y molecular, sin embargo, la superficie terrestre está constituida por un sinnúmero de combinaciones de compuestos orgánicos e inorgánicos, entonces el espectro observado en los objetos tiene un gran rango de componentes.



Debido a lo anterior la temperatura también puede afectar al espectro de la energía reflejada y emitida por los objetos, los objetos con mayor temperatura emiten la mayor parte de su radiación con menores longitudes de onda, en caso contrario los objetos más fríos presentan mayores longitudes.

La mayor parte de la radiación emitida por los cuerpos son ondas que se encuentran por debajo de la banda visible; por ello no podemos ver la mayoría de la energía con el ojo humano, gran parte de lo que percibimos es energía reflejada a través del objeto, lo cual es una de cosas que pueden pasar con ella, no obstante, esta energía también puede ser transmitida (a través del objeto) o absorbida (por el objeto); estos conceptos se describen a continuación:

La transmisión de la energía (conocida como transmitancia) se refiere al movimiento de energía a través de la superficie terrestre, el aporte de esta depende de la longitud de onda electromagnética y es medida como el radio entre la radiación transmitida y la radiación que incide.

La energía reflejada o reflectancia se refiere al radio entre la radiación magnética reflejada y la cantidad total de radiación que incide; la reflectancia presenta un reflejo especular cuando el objeto o superficie de incidencia es plana, por otro lado, si la superficie es rugosa la energía se refleja en todas direcciones y entonces ocurre un reflejo difuso.

Gran parte de los objetos que hay en la tierra presentan reflejos especulares y difusos, gracias a ello se puede conocer el tipo de objeto en particular gracias a su reflejo en ambas formas dependiendo de su composición.

La absorción o absorbancia se refiere a la atenuación de la intensidad de la radiación cuando esta incide sobre el objeto, como ya se mencionó anteriormente, esta absorción puede darse por los componentes atmosféricos.

Cuando la luz solar incide en los objetos, más de uno de estos tres fenómenos tienen ocurrencia al mismo tiempo, un ejemplo de eso es que cuando un objeto

absorbe energía de la luz del sol, este se calienta y emite a una longitud de onda diferente la cual es conocida como energía infrarroja (Aguilar, s/f).

Cada material presenta los anteriores comportamientos de maneras diferentes, tales propiedades hacen posible la identificación de distintos substratos de la superficie terrestre que pueden ser separados y caracterizados por su firma espectral cuyo término hace referencia a un perfil específico de radiancia emitida por diferentes objetos (véase Figura 1.3).

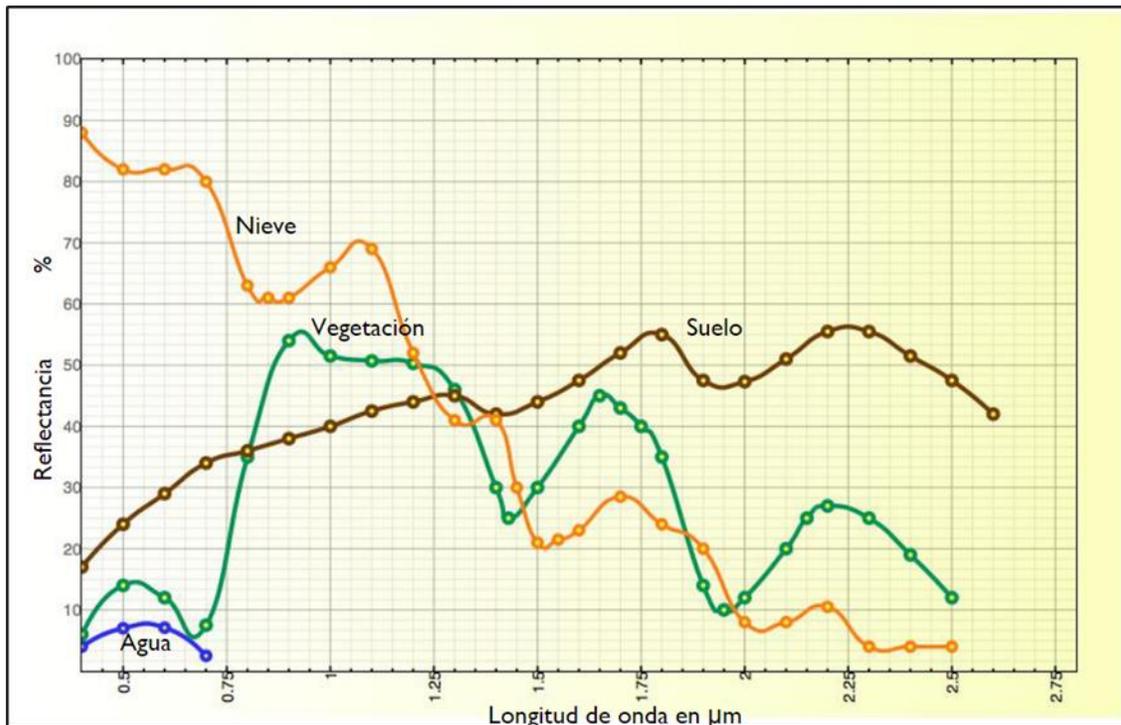


Figura 1.3 Firmas espectrales de nieve, vegetación, suelo y agua. Fuente: Diseño de Modelos de Calidad del Agua Mediante el Uso de la Percepción Remota, 2011.

1.5 Imágenes satelitales

Las imágenes satelitales son representaciones visuales de la información captada por un sensor instalado a bordo de un satélite artificial, están compuestas por un conjunto de elementos de igual tamaño, denominados píxeles, los cuales se encuentran dispuestos en filas y columnas. Los píxeles contienen un valor numérico o número digital, producto de la captación de energía reflejada por los objetos en la superficie terrestre a través de distintos sensores (Díaz González et al.,2014).

En la recopilación de estas imágenes se deben tomar en cuenta cuatro resoluciones características, las cuales nos dicen cuán nítida es la imagen:

- Espacial: Se define como la separación mínima entre dos objetos que puede diferenciar el sensor, está relacionada con el concepto IFOV (*Instantaneous Field Of View*), el cual se refiere al área de la superficie representada en cada píxel, por ello se puede afirmar que, a mayor resolución espacial, el píxel será menor y así obtendremos imágenes más claras.

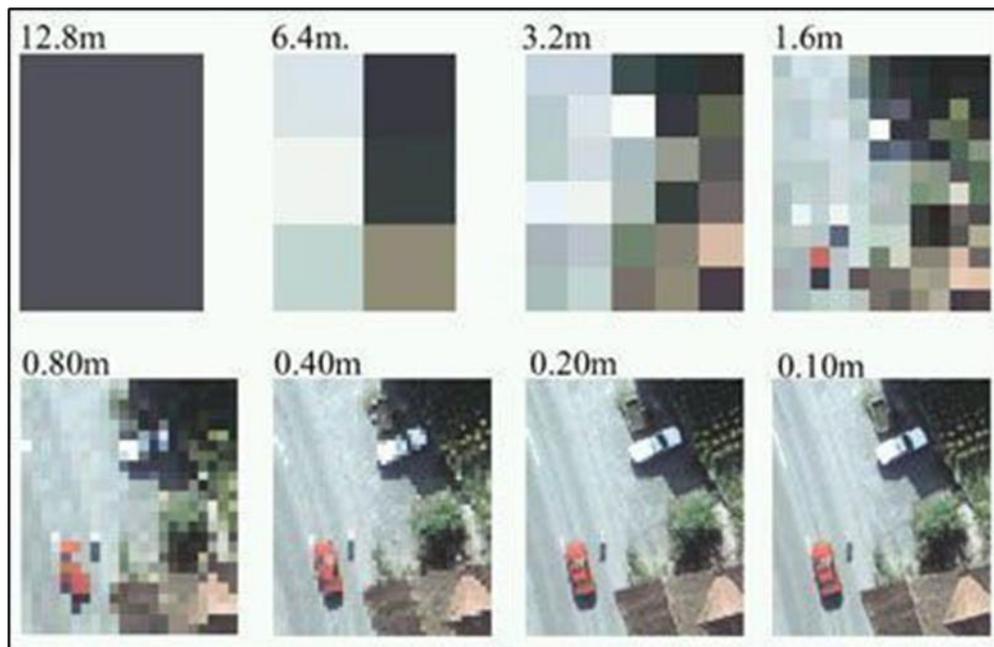


Figura 1.4 Ejemplo de resolución espacial, fuente: <https://agrotendencia.tv/agropedia/>

Espectral: se refiere al número y tamaño de las bandas que puede detectar un sensor; cada uno se diferencia por la porción del espectro que captan.

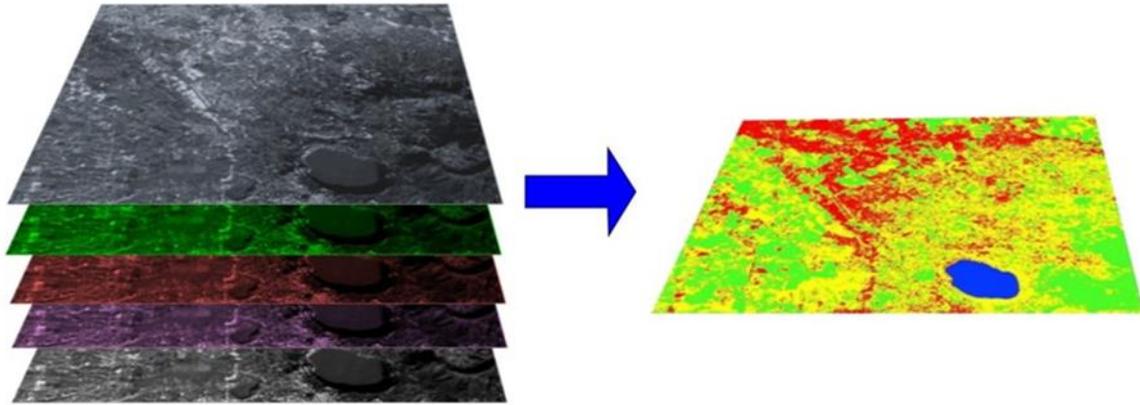


Figura 1.5 Ejemplo de resolución espectral, fuente: <https://semiautomaticclassificationmanual-v5.readthedocs.io/>

Radiométrica: hace referencia al rango de niveles digitales que le es posible registrar en cada banda, es decir, la capacidad que posee el sensor para visualizar distintos objetos en el mismo rango del espectro electromagnético. Esta resolución es normalmente medida en valores binarios (bits).

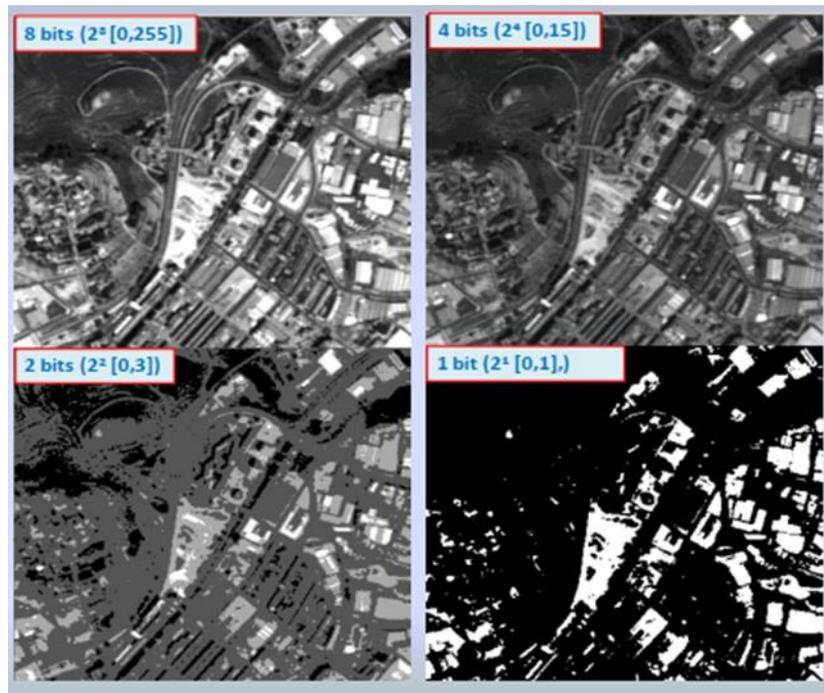


Figura 1.6. Ejemplo de resolución radiométrica, fuente: <https://alfageomatics.com/>

Temporal: la radiación temporal se refiere al periodo de tiempo que tiene el satélite para registrar imágenes en la misma área de la superficie terrestre.



1.6 Satélites

Actualmente existe una extensa disposición de satélites en el mercado, los cuales obtienen datos remotos con diversas características que dan prioridad a una o varias de las cuatro resoluciones (espacial, espectral, radiométrica y temporal); algunos de estos satélites son: Landsat, SPOT (*Systeme Probatoire l'Observation de la Terre*), Sentinel. MODIS, sistemas de radares de satélites, el radiómetro avanzado de muy alta resolución (AVHRR), los satélites NOAA-10, Sojuzkarta, etc.

Si de resolución espacial se trata, los satélites que muestran un mejor desempeño y que además son de uso libre son: Landsat con resoluciones de 30 y 100 metros, Sentinel con resoluciones de 20, 30 y 60 metros y SPOT con resolución de 20 metros por píxel.

Otra importante diferencia a tomar en cuenta que ofrecen los satélites es la cantidad de bandas con las que trabajan, por ejemplo, si se desea trabajar con imágenes a color natural, bastará contar con bandas roja, verde y azul, sin embargo, si se pretende trabajar aspectos relacionados con la vegetación, temperatura, u otros fenómenos meteorológicos se deberá optar por un satélite que disponga de bandas fuera del espectro visible (normalmente bandas como infrarrojo cercano e infrarrojo de onda corta). Algunos ejemplos de disponibilidad de bandas son: Landsat 7 que posee 8 bandas espectrales, Landsat 8 cuenta con 11, Sentinel con 13 y SPOT apenas posee 4 de ellas.

Debido a la disponibilidad y cantidad de información en el presente trabajo se utilizan los satélites Landsat 7 y 8, los cuales fueron lanzados en enero de 1999 y en abril de 2013, respectivamente.

Landsat 7 tiene la capacidad de transmitir hasta 532 imágenes por día, tiene una órbita heliosincrónica (recorre el mismo lugar a la misma hora) y cubre la superficie terrestre en 15 días (INEGI, sin fecha).



Tabla 1.1. Resoluciones características de Landsat

Modo Espectral	Resolución			
	Espacial (metros)	Espectral (micra)	Radiométrica	Temporal
Multiespectral	Banda 1 (azul)	0.52-0.90	8 Bits	16 Días
	Banda 2 (verde)	0.45-0.52		
	Banda 3 (Roja)	0.53-0.61		
	Banda 4 (Infrarrojo Cercano, NIR)	0.63-0.69		
	Banda 6 (Infrarrojo medio)	1.55-1.75		
	Bandas 5 y 7 (Infrarrojo de onda corta, SWIR 1 y 2)	2.09-2.35		
Pancromática	Banda 8	0.52-0.90		

Fuente: Elaboración propia.

Landsat 8 por su parte posee características similares a Landsat 7, sin embargo, fue adicionado con dos sensores OLI (*Operational Land Imager*) y TIRS (**Thermal Infrared Sensor**). Gracias a la mejoría en los instrumentos del satélite fue posible incorporar nuevas bandas espectrales como la banda 1 que es un canal profundo en el azul visible (diseñado especialmente para el estudio de recursos hídricos) y un nuevo canal infrarrojo que tiene la capacidad de transmitir 400 imágenes al día las cuales con una resolución espacial de 30 metros (IGAC, 2013).

Tabla 1.2. Resoluciones características de Landsat 8

Modo Espectral	Resolución			
	Espacial (metros)	Espectral (micra)	Radiométrica	Temporal
Multiespectral	Banda 1 (Aerosol costero)	0.43-0.45	16 Bits	16 Días
	Banda 2 (Azul)	0.45-0.51		
	Banda 3 (Verde)	0.53-0.59		
	Banda 4 (Roja, NIR)	0.64-0.67		
	Banda 5 (Infrarrojo cercano)	0.85-0.88		
	Bandas 6 y 7 (Infrarrojos de onda corta, SWIR 1 y 2)	1.57-1.65		
	Banda 9 (Cirrus)	2.11-2.29		
	Banda 10 (Infrarrojo térmico 1)	1.36-1.38		
	Banda 11 (Infrarrojo térmico 2)	10.60-11.19		
Pancromática	Banda 8	11.50-12.51		

Fuente: Elaboración propia



2 Estado del arte

Existen diversos trabajos de investigación relacionados al desarrollo de modelos que permiten la predicción de parámetros de calidad a partir de imágenes satelitales, por ejemplo: para pronosticar la calidad del agua del río Tigris utilizando imágenes satelitales de Landsat 8 y un algoritmo de regresión lineal (Wael Ahmed et al., 2023), para determinar las concentraciones de clorofila alfa en los embalses Fongshan y Tsengwen en Taiwán, haciendo uso de las imágenes de Sentinel 2 y un modelo de inversión (Chu H y He, 2023), O bien, para determinar las concentraciones de algas verde azules, Sólidos Suspendidos Totales (SST) y clorofila alfa (Chl_a) utilizando imágenes de Envisat, modelos de correlación combinados con técnicas de corrección atmosférica en el lago Manyame y Chivero en Zimbabwe (Chawira et al., 2013), entre otros.

Para el caso de embalses dentro de la República mexicana en 2011, fueron desarrollados modelos de regresión lineal para la presa Valle de Bravo. El fin del desarrollo de estos modelos fue estimar algunos parámetros ópticos de calidad del agua (Índice de estado Trófico, Turbiedad y Sólidos Disueltos Totales), a partir del análisis estadístico de diversas combinaciones de bandas de imágenes proporcionadas por el satélite Landsat 7 y parámetros de calidad medidos en sitio, para ello se obtuvieron 100 datos como resultado de dos campañas de muestreo tomadas en diversos puntos de la zona de estudio.

Al concluir este trabajo se observó que las bandas que proporcionaron más información para la predicción de los parámetros antes mencionados fueron las bandas 1, 2 ,3 y 4. En referencia a los modelos, se concluyó que estos no son aplicables a diferentes cuerpos de agua, sin embargo, la metodología descrita dentro del trabajo de investigación es la adecuada para ser adaptada a diferentes áreas de estudio (Sepúlveda, 2011).

Con el paso de los años el aumento de la popularidad de la percepción remota en el monitoreo de cuerpos de agua ha ido en incremento, y como consecuencia de la escasa cantidad de datos existentes para este fin, en septiembre del 2019 se desarrolló un algoritmo que permite emparejar automáticamente datos comunes de



calidad del agua (profundidad del Disco Secchi, Solidos Disueltos Totales y Concentración de Clorofila Alfa) con valores de reflectancia asociados a diversos sitios de muestreo.

Para su creación fue necesario extraer información de dos grandes bases de datos, en su mayoría se conformadas por datos de los cuerpos de agua de Estados Unidos: LAGOS-NE y WQP (*Water Quality Portal*), las cuales en conjunto proporcionan más de 379 mil datos de muestreo.

El algoritmo permite buscar imágenes de Landsat 5, 7 y 8, asociándolas automáticamente con las fechas de muestreo reportadas en LAGOS-NE y WQP, de la misma forma el algoritmo es capaz de extraer valores de reflectancias por píxel, proporcionados por los productos de la colección Tier 1, que provee la USGS (Servicio Geológico de Estados Unidos) mediante la plataforma Google Earth Engine, dando lugar a la creación del banco de datos para percepción remota en cuerpos de agua más grande del mundo: AquaSat (Ross, 2019), en consecuencia dicha base de datos ha sido utilizada para crear modelos de predicción utilizando diversos algoritmos como redes neuronales, árboles de decisión, Random Forest, XGBoost, regresión logística, etc (Nasir et al., 2023).

Dos años más tarde de la creación de AquaSat en Estados Unidos se desarrollaron diversas pruebas empleando algoritmos de inteligencia artificial para predecir la claridad de 103 lagos a lo largo de EE. UU., los cuales emplearon 250,760 datos de reflectancias y profundidad de Disco Secchi, todos ellos tomados y corregidos de la base AquaSat combinándolos con parámetros “estáticos” que inciden en la claridad de las aguas para cada cuenca de estudio (cobertura forestal, porcentaje de urbanización, porcentaje de tierras de cultivo, etc.).

Para el desarrollo del modelo, se discriminaron datos de reflectancias cuyas imágenes presentaban nubosidades, de igual modo, se descartaron valores cuyos puntos de muestreo se localizaban a las orillas de los lagos o que pudieran verse afectados por la presencia de vegetación.



Se utilizó el algoritmo XGBoost el cual es comúnmente aplicado en temas de ingeniería de recursos hídricos, incluida la hidroclimatología (Niazkar et. al, 2023) teniendo como base de funcionamiento los árboles de decisión, para su adecuación se dividió la muestra, el 80% de los datos fue usado para el adiestramiento y el sobrante sirvió para comprobar la fiabilidad del predesarrollo, de la misma forma, con el fin de prevenir el sobre entrenamiento del modelo se utilizaron métodos de validación cruzada para garantizar la independencia de los datos.

Los resultados de tales trabajos arrojaron que la mejor combinación de las variables utilizadas en el modelo de predicción son las reflectancias de las bandas verde, azul y roja combinadas con 27 parámetros estáticos, lo cual arrojó errores de ajuste menores al 38% y un coeficiente de determinación final (R^2) del 89%. Adicionalmente se comprobó que para este conjunto de información por lo menos el 50% de la variabilidad del modelo combinado está dada por parámetros ópticos. (Topp et al, 2021)

Para el año 2022 en China, se utilizaron imágenes del satélite Sentinel para entrenar diversos modelos de inteligencia artificial que permitieran monitorear la calidad del agua en zonas costeras.

El sitio estudiado fue la bahía de Shenzhen en Hong Kong cuya problemática radica en la contaminación acuática debida a la eutrofización y a la proliferación de microalgas que dan lugar al fenómeno de marea roja, estos efectos se han incrementado debido al crecimiento poblacional acelerado, lo cual ha amenazado el desarrollo del ecosistema y la salud de la población cercana.

Para el desarrollo de estos modelos se recopilaron 64 muestras de 32 puntos de muestreo y se adicionaron 30 datos reportados por el Departamento de Protección Ambiental de Hong Kong (HKEPD), dichas muestras contenían datos de concentración de clorofila alfa, oxígeno disuelto y turbiedad.

Los muestreos fueron relacionados con imágenes Sentinel, filtrando aquellas que tuvieran más del 20% de nubes. Para el desarrollo de estos modelos se crearon



combinaciones de bandas con índices espectrales y datos meteorológicos como la velocidad promedio del viento, la temperatura del aire y la presión promedio del aire.

Los algoritmos utilizados fueron XGBoost, Redes Neuronales y Regresión de Vector Soporte (SVR), lo cuales fueron evaluados con cuatro métricas (error, sesgo, la pendiente de la ecuación de regresión lineal y el logaritmo del error cuadrático medio).

El mejor desempeño fue para el algoritmo XGBoost presentando los mejores resultados en las métricas antes mencionadas con los escenarios de combinación de parámetros climatológicos, bandas e índices espectrales, por ejemplo, se encontró que las concentraciones de clorofila poseen una correlación positiva con la temperatura (Zhu et al., 2022).

En el mismo año en la India se llevó a cabo un estudio donde se utilizó como cuerpo de estudio la laguna de Chilika donde se obtuvieron 61 muestras compuestas por parámetros como Clorofila Alfa (Ch_a), Materia Particulada en Suspensión (MPS) y la Profundidad del Disco Secchi para ser relacionadas con imágenes con datos de reflectancia proporcionadas por Sentinel, con el fin de obtener modelos que permitiera predecir el valor de la Profundidad de la Zona Eutrófica (PZE). La PZE es un indicador de las condiciones de luz bajo el agua en conjunto con otro parámetro llamado Coeficiente de Atenuación (K_d).

Es usual que en sistemas de percepción remota los valores de PZE sean estimados a partir de la siguiente expresión:

$$PZE = \frac{4.605}{Kd(RPA)}$$

Donde:

PZE= Profundidad de la Zona Eutrófica

Kd= Coeficiente de Atenuación

RPA= Radicación Fotosintética Activa



En dicho estudio se postula que es posible estimar $K_d(\text{RPA})$ con modelos empíricos a partir de datos del procesamiento matemático de valores de reflectancia, por ello, se analizaron 6 modelos empíricos cuyo rendimiento fue analizado utilizando parámetros como R^2 (Coeficiente de Determinación), RMSE (Error cuadrático medio) y MADP (Diferencia Porcentual Media Absoluta).

Como resultado de ello se llegó a que los modelos que utilizaban la diferencia de las bandas 2 y 4 y 3 y 5, son útiles para estimar los valores de $K_d(\text{RPA})$, del mismo modo se concluyó que los valores de (MPS) y la profundidad del Disco Secchi están relacionados de manera exponencial, mismo caso para Ch_a y la PZE.

Finalmente, el modelo con mayor desempeño para predecir $K_d(\text{RPA})$ arrojó un R^2 de 0.78 utilizando las bandas 2 y 4; por su parte para la estimación de la Profundidad de la Zona Eutrófica (PZE), se logró obtener un modelo con un R^2 de 0.77 y 0.78 utilizando las bandas 2 y 4 y 4 y 5, respectivamente (Roy y Das, 2022).



Objetivo

Desarrollar un modelo que permita monitorear la calidad del agua en embalses de tipo lénticos, utilizando redes neuronales y datos extraídos de sensores remotos correspondientes a cuerpos de agua mexicanos con enfoque metodológico orientado a la presa Miguel Alemán en Valle de Bravo.

3 Metodología

3.1 Reconocimiento del sitio de interés

La presa Miguel Alemán mejor conocida como presa de Valle de Bravo se localiza al oeste de la ciudad de Toluca, situada en los $19^{\circ} 13' 26''$ N y $100^{\circ} 7' 19.5$ W y a 1,759 msnm; fue construida por la Comisión Federal de Electricidad en el año de 1947 como parte del sistema hidroeléctrico Miguel Alemán cuando este se encontraba en operación, para el año de 1982 las presas que formaban parte de él cambiaron de jurisdicción hasta llegar a formar parte el sistema hidráulico Cutzamala. Según datos de CONAGUA (CONAGUA, 2005), la presa fue integrada en el año de 1985 durante la segunda etapa de construcción del sistema, proporcionando un flujo volumétrico de 6,000 L/s, una capacidad de almacenamiento de 400 millones de metros cúbicos (inicialmente).

Valle de Bravo tiene una gran importancia para los municipios aledaños y para la población del Estado y la Ciudad de México, puesto que, proporciona más del 30% del agua que envía el sistema Cutzamala a la población del valle de México, abasteciendo 11 delegaciones de la Ciudad de México, así como 11 municipios del Estado de México.

Cabe mencionar que el sistema Cutzamala es de los más relevantes en su naturaleza a nivel mundial, tanto por el nivel de agua que aporta (485 millones de metros cúbicos anuales) como por los desniveles con los que funciona.

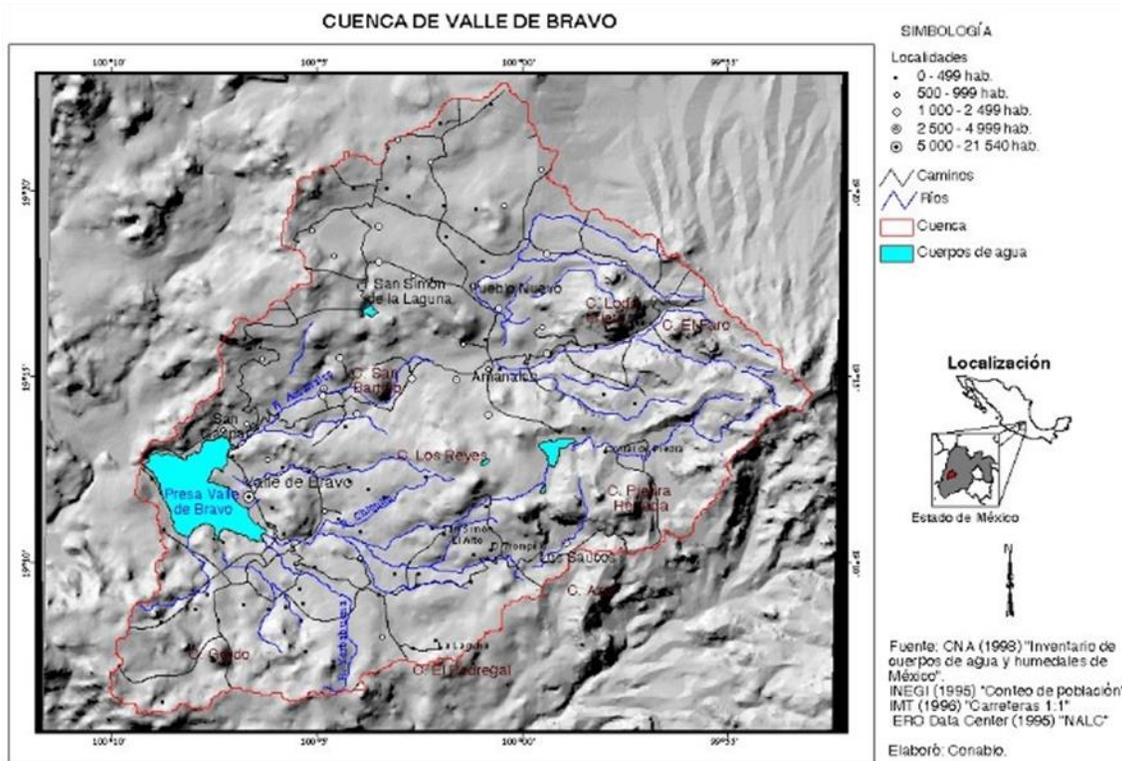


Figura 3.1 Cuenca Valle de Bravo. Fuente: <https://www.biodiversidad.gob.mx>.

El embalse es también utilizado con fines recreativos que involucran actividades acuáticas, convirtiendo al municipio de Valle de Bravo en uno de los destinos turísticos más emblemáticos y atractivos del Estado de México, aportando grandes beneficios económicos a la región.

La cuenca Amanalco Valle de Bravo, pertenece a la región hidrológica número 18 del río Balsas, se encuentra localizada al poniente del estado de México, abarca los municipios de Amanalco, Valle de Bravo (casi en su totalidad) y algunas partes de los municipios de Villa Victoria, Villa de Allende, Temascaltepec y Donato Guerra, la cual cubre una superficie de 61,548.47 hectáreas; los principales cuerpos de agua son el río Amanalco y la presa Valle de Bravo (IMTA,2012).

3.1.1 Clima

En la cuenca Amanalco Valle de Bravo las temperaturas medias mensuales más elevadas se presentan durante los meses de abril y mayo, las cuales oscilan entre los 16°C y los 21°C, por su parte las temperaturas más bajas se presentan de diciembre a febrero con promedio de 9.8°C a 11.2°C.



Debido a las variables de relieve y altimetría se originan distintos climas, entre los cuales se encuentra el clima semicálido (con temperaturas superiores a los 22°C, que se presentan posterior al solsticio de verano), templado subhúmedo (con temperaturas que varían de los 5°C a los 18°C) y semifrío subhúmedo (presentando una variación de temperaturas que va de los 5°C a los 12°C).

Por su parte, en Valle de Bravo el clima predominante es el subhúmedo, los meses más cálidos son de mayo a agosto presentando las temperaturas más altas antes del solsticio de verano.

3.1.2 Orografía

Las elevaciones de la cuenca varían entre los 1,800 a 3,600 msnm, esta se encuentra situada en el eje volcánico transversal, la subprovincia de Mil Cumbres y la depresión del Balsas. El relieve está compuesto de zonas montañosas y lomeríos, sobresaliendo volcanes y montañas que alcanzan los 3,500 metros sobre el nivel del mar.

3.1.3 Vegetación

Debido a las condiciones orográficas y a la climatología dentro de la región, predominan los bosques de coníferas y encinos, los principales tipos de vegetación encontrados en la zona son:

- Bosque de Oyamel. Localizado en las partes altas de la cuenca (arriba de los 2,900 msnm), se presentan los tres tipos de estratos de vegetación, arbóreo, arbustivo y herbáceo, el primero de ellos con alturas típicas de 30 metros, la especie predominante es la *Abies Religiosa* donde sus copas suelen cubrir más del 80% de la superficie.
- Bosque de pino. Estos se localizan en elevaciones por encima de los 2,400 msnm, el estrato más importante es el arbóreo con alturas de 20 a 30 metros, aunque los pinos son característicos de las montañas de la región, no llegan a ser la vegetación predominante.
- Bosque de pino-encino. Este tipo de vegetación del tipo *Pinus* se encuentra por encima de los 1,800 msnm, presenta los tres tipos de estrato, siendo el



predominate de tipo arbóreo con 60% de cobertura de la superficie, teniendo alturas promedio entre 15 y 25 metros.

- Pastizal inducido. Este tipo de vegetación es utilizada para sostener las actividades ganaderas de la zona, las especies características son *Poaceae*, *Cyperaceae* y *Asteraceae*; se encuentran en alturas de 3,000 msnm a 2,400 msnm.

3.1.4 Hidrología

En toda la cuenca existen manantiales, corrientes permanentes e intermitentes, los cuerpos de agua perenes son principalmente utilizados para el riego y el suministro de agua potable de las comunidades cercanas.

La cuenca Amanalco-Valle de Bravo es una de las regiones hidrológicas más importantes del país debido a la extensión y volumen de sus corrientes superficiales, del mismo modo se encuentra en una zona que por sus características geomorfológicas y topográficas permite una gran captación de agua de manantiales y pluvial.

Esta cuenca a su vez se divide en 28 subcuencas con una superficie total de 775.6 km² que facilitan el estudio, manejo y el monitoreo de los recursos naturales de la región. Entre las subcuencas de mayor importancia se encuentran las de Amanalco, Río San Diego y la del Río La Hierbabuena.

La subcuenca del Río Amanalco posee la extensión territorial más grande en comparación con las antes mencionadas (227.9 km²), se encuentra en la cabecera municipal de Amanalco y a su vez se subdivide en 8 microcuencas delimitadas por el río y sus afluentes.

La subcuenca del Río San Diego ocupa el segundo lugar respecto a la extensión territorial (con 40.19 km²), esta subcuenca se caracteriza por poseer un alto índice de vegetación e infiltración; por último, la del Río La Hierbabuena tiene una superficie de apenas 13.22 km², gracias a sus características climatológicas y morfológicas, la captación de agua se ve favorecida.



Es importante mencionar que la mayoría de las subcuencas tienen como punto de drenaje el embalse de la presa Valle de Bravo a través de flujos superficiales y subterráneos, los últimos debidos a la actividad volcánica de la zona.

3.1.5 Capacidad del embalse

Gracias a las alturas en las que se encuentra la cuenca (mayor a 2,000 msnm) y las grandes precipitaciones (que ascienden a los 1,024.7 milímetros anuales) se dio pie a la construcción de la presa Miguel Alemán (que más tarde se convertiría en el cuerpo de agua más importante dentro de la cuenca), aunado a esto, toda la cuenca cuenta con cauces permanentes de aguas limpias alimentados por manantiales.

Según datos del IMTA (IMTA,2012) la cuenca tiene una precipitación promedio anual de 973,966.610 m³, de los cuales por lo menos se evapora un 48%, mientras que el 35% recarga los mantos acuíferos y el 17% restante escurre de manera superficial, por su parte, en la presa se registran precipitaciones de hasta 1,310 milímetros anuales en la cortina.

En cuanto al agua superficial, la cuenca cuenta con ríos de gran importancia, por ejemplo, el Río Amanalco, Río Carrizal, Río la Hierbabuena, entre otros. Para el caso de los manantiales se tiene un registro de al menos 841 en toda la cuenca, 396 de ellos se encuentran en el municipio de Valle de Bravo, los cuales en conjunto producen un volumen de agua hasta de 3.84 m³/s.

En lo que respecta a la presa, cuenta con una capacidad volumétrica de hasta de 391 millones de metros cúbicos y opera con un volumen promedio de 311.6 millones de metros cúbicos, lo cual se traduce en una operación al 80% de su capacidad máxima, posee una superficie de 1,885 hectáreas, con una longitud máxima de 7.3 Km, ancho de 6.3 Km y una profundidad media de 21.1 metros (IMTA, 2012).

3.1.6 Uso del recurso hídrico

Como ya se mencionó, la presa de Valle de Bravo inicialmente se había construido con fines de generación hidroeléctrica, sin embargo, de manera paulatina se fueron construyendo más centrales de este tipo por lo cual Valle de Bravo no sería suficiente para satisfacer esta necesidad, no obstante, a finales del siglo XX surgió



una nueva problemática a cubrir, la cual era hacerle frente a la poca o casi nula sostenibilidad del Valle de México para dotar a su población con agua potable.

Debido al incremento exponencial de la inmigración a la Ciudad de México a principios del siglo XX, emerge la necesidad de traer agua de las cuencas aledañas como es el caso de la cuenca del Río Lerma en Toluca, la cual a principios del año 1950 ya presentaba signos importantes de sobreexplotación (IMTA, 2021). Adicionalmente, los problemas de hundimientos diferenciales por la explotación de los mantos acuíferos y la contaminación de las aguas de los ríos trajeron como consecuencia la necesidad de captar agua de fuentes externas, es así como se comienza a utilizar los afluentes del río Cutzamala, dando pie al inicio de la conformación de uno de los más grandes sistemas de abastecimiento en el mundo, el cual integra a la cuenca Valle de Bravo Amanalco como una de las zonas clave para alimentarlo.

En la primera etapa de construcción se integra a la presa Villa Victoria aportando 4 m³/s pero es hasta la segunda etapa que se alcanza un suministro de 10 m³/s integrando a la presa Valle de Bravo, así como la construcción de plantas de bombeo (2, 3, 4 y 5). Es durante la tercera etapa cuando se integran las presas Chilesdo y Colorines proporcionando 9 m³/s adicionales.

En total este sistema cuenta con 7 presas de las cuales tres son de almacenamiento (Tuxpan, Ixtapan del Oro y Colorines) y cuatro derivadoras (El Bosque, Valle de Bravo, Villa Victoria y Chilesdo) , seis macroplantas de bombeo (para vencer un desnivel de 1,100 m), un acueducto (de 205.7 Km con tubería de acero y concreto de diámetros entre 1.07 y 3.5 m), un túnel (de 43.99 Km), un canal abierto (de 72.55 Km) y una planta potabilizadora (que consta de 5 módulos de 4 m³/s cada uno) que envían 14,500 L de agua potable a nueve delegaciones de la Ciudad de México y 13 Municipios mexiquenses (IMTA, 2012).

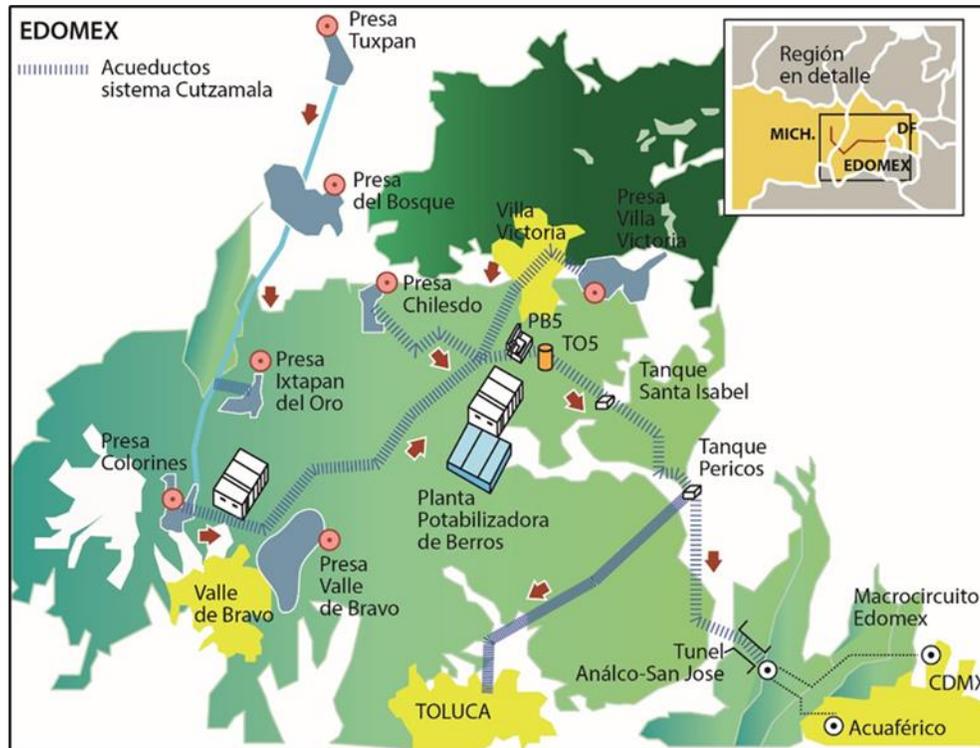


Figura 3.2 Esquema general de Sistema Cutzamala. Fuente: <https://www.gob.mx>

3.2 Problemática

La cuenca Valle de Bravo es una de las generadoras de agua más importantes de las seis cuencas que conforman el Sistema Cutzamala, el cual abastece el 40% del agua potable consumida en el área metropolitana de la Ciudad de México y Toluca (IMTA, 2012).

La cuenca posee gran variedad de flora y fauna, los bosques son esenciales para especies endémicas y migratorias (como la mariposa monarca), sin embargo, la cuenca ha venido presentando señales evidentes de deterioro ambiental; todo esto como respuesta al crecimiento urbano desmedido, asentamientos poblacionales que no cuentan con servicios básicos, las actividades primarias y el incremento del turismo en la zona.

Desde hace algunas décadas, el embalse ha sufrido procesos de eutrofización, es decir, que la calidad del recurso se ha visto mermada debido al enriquecimiento de nutrientes, principalmente nitrógeno y fósforo, que son de gran importancia en la cadena alimentaria, pero cuando son descargados en altas concentraciones



principalmente procedentes de la actividad humana (en su mayoría por descargas de drenajes locales al Río Amanalco), estos nutrientes en combinación con las buenas condiciones del embalse dan a lugar un crecimiento acelerado de materia orgánica y a su vez provocan la proliferación de colonias de algas.

Uno de los inconvenientes derivado de la presencia de estos microorganismos en cuerpos de agua es que proporcionan un aspecto poco confiable a la misma, ya que producen un color verdoso, olor y sabor desagradables, con ello se limita el aprovechamiento del agua de la cuenca.

El color verde presente en el agua impide el paso de la luz a profundidades que antiguamente si alcanzaba; provocan que algunos de estos microorganismos flotantes se hundan y mueran debido al mismo crecimiento acelerado y al agotamiento de los nutrientes, esta sustancia orgánica muerta es descompuesta por bacterias que consumen el oxígeno disponible en el agua, lo cual puede generar toxinas letales para animales y plantas.

Las cianobacterias (o algas verde-azules) y la producción de toxinas muestran mayor crecimiento cuando existen factores como temperaturas entre 18° C y 25°C, altos niveles de eutrofización en los cuerpos de agua, salinidad, pH y la presencia de metales, sin embargo, se debe aclarar que no siempre existe relación entre la masa de cianobacterias y el nivel de toxinas presentes (Navarro, 2002).

En la actualidad la toxicidad de los afloramientos de cianobacterias aparece como un importante problema en el agua del embalse, ya que, existen distintos estudios que demuestran la presencia de cianotoxinas, especialmente del tipo microcistina.

De acuerdo con recientes investigaciones por parte de la Universidad Nacional Autónoma de México (UNAM, 2019), en el embalse la microcistina se encuentra en concentraciones de 9.57 $\mu\text{g/l}$ y de 0.097 $\mu\text{g/l}$, en la época seca (enero) y lluviosa (septiembre), todas ellas por encima de las concentraciones medias letales, que son de 5.34 $\mu\text{g/l}$ y de 0.35 $\mu\text{g/l}$, respectivamente.



Gracias a su posición y altitud el embalse se comporta como un cuerpo de agua tropical lo cual propicia un ambiente óptimo para la proliferación de estas cianotoxinas, las cuales resultan generar efectos adversos en la salud como reacciones alérgicas o enrojecimiento, malestar estomacal, diarrea, vómito, daño renal y hasta la muerte debido a hemorragia o falla hepática (pues estas son catalogadas como hepatotóxicos específicamente en mamíferos).

Las afecciones causadas por estos afloramientos aparecen como resultado del contacto con la piel o ingesta crónica de bajas concentraciones, mediante el consumo de agua o animales que han consumido y acumulado dichas toxinas (Navarro, 2002).

Lo anterior denota la importancia de cuidar los niveles de eutrofización en el embalse, para ello, es importante utilizar parámetros que ayuden a estimar las condiciones del cuerpo de agua en cuanto a eutrofización se refiere.

3.3 Índice de estado trófico a partir de la profundidad del Disco Secchi

Una de las primeras medidas propuestas para estimar los niveles de contaminación en lagos es el Índice de Estado Trófico (TSI); fue propuesto por Robert Carlson en 1977, este es una medida clasificatoria para categorizar los lagos con base en su capacidad de producción biológica. El estado trófico se define como el peso total de la biomasa en una masa de agua determinada en el momento de la medición. Debido a que son de interés público, el índice de Carlson puede determinarse utilizando varios parámetros como la concentración de clorofila, fósforo y la transparencia del Disco de Secchi.

El TSI se obtiene más a menudo utilizando la transparencia del Disco de Secchi en una columna de agua; esta transparencia indica el alcance de la refracción de la luz a través de la turbidez y el color del agua, este nivel de refracción se modifica debido a la presencia de sistemas coloidales y sólidos en suspensión, volátiles y disueltos.

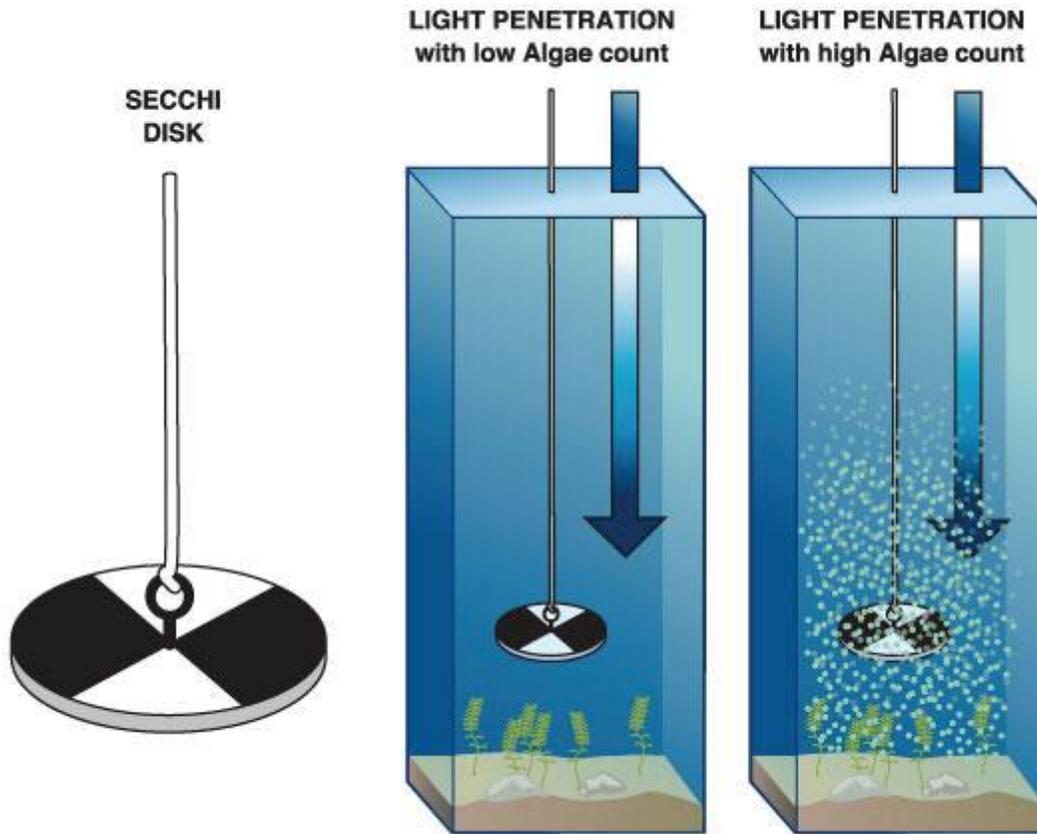


Figura 3.3 Condiciones necesarias para el desarrollo de las hierbas marinas. (2023, enero 23). Issuu. <https://issuu.com/seagrantpr/docs/guia-hierbas-marinas/s/17969558>.

La ecuación que permite determinar el TSI a partir de la profundidad del disco de Secchi se muestra a continuación:

$$TSI = 10 \left(6 - \left(\frac{\ln PDS}{\ln 2} \right) \right)$$

Donde:

PDS= Profundidad del Disco de Secchi, en metros.

Ln= Logaritmo Natural

Los valores de TSI varían en un rango de 0 a 100, es decir de oligotrófico a hipertrófico; se estima con valores iniciales de profundidad del disco de 64 metros lo cual corresponde a un valor de TSI=0 y cada incremento de 10 unidades de TSI representa un decremento del 50% en la profundidad del disco.



Tabla 3.1 Escala de valores de estado trófico en función de la profundidad del Disco Secchi.

Estado	TSI	Profundidad (m)
Oligotrófico (TSI<30)	0	64
	10	32
	20	16
	30	8
Mesotrófico (TSI<60)	40	4
	50	2
	60	1
Eutrófico (TSI<90)	70	0.5
	80	0.25
	90	0.12
Hipertrófico (90<TSI<100)	100	0.12

Fuente: Modificado de Carlson (1977).

Las categorías de clasificación trófica se describen a continuación:

- Oligotrófico. Un cuerpo de agua oligotrófico es aquel con un bajo nivel de productividad biológica, aguas claras, altas concentraciones de oxígeno, flora y fauna en cantidades moderadas y por ende una baja concentración de nutrientes.
- Mesotrófico. Estos cuerpos de agua comúnmente poseen aguas claras, plantas acuáticas, niveles medios de productividad y concentraciones medias de nutrientes.
- Eutrófico. Estos lagos se caracterizan por tener un alto nivel de productividad, gran cantidad de plantas y aguas claras, o bien, baja cantidad de plantas y poca claridad en el agua, de igual forma tienen gran capacidad para soportar la vida acuática.
- Hipertrófico. Se refiere a aquellos embalses con grandes cantidades de nutrientes, una altísima productividad, una muy pobre claridad del agua, abundantes plantas acuáticas y capacidad para soportar la vida acuática.

Los efectos asociados con la variación del estado trófico pueden ser medidos a través de distintas características morfométricas, químicas y biológicas para así poder conocer las consecuencias de la eutroficación a mayor escala.



3.4 Recopilación de datos

La Comisión Nacional del Agua (CONAGUA) lleva a cabo el monitoreo de los cuerpos de agua más importantes del país, todo ello a través de la Red Nacional de Medición del Agua, la cual recopila datos de cuerpos de agua lóticos, lénticos, costeros y subterráneos, en los cuales se incluyen parámetros fisicoquímicos y microbiológicos de acuerdo con el tipo de cuerpo de agua.

Para el caso del sitio de interés, se tienen disponibles diversas fechas de muestreo asociados a varias coordenadas donde fueron recogidas las muestras en las cuales se pueden identificar aquellos que pueden asociarse como una variable óptica, es decir, la profundidad del Disco de Secchi (PDS), los sólidos suspendidos totales (SST) y la concentración de clorofila alfa (Cholof_A). Adicionalmente, la base de datos ofrece ciertos parámetros climatológicos que pueden influir directamente en las condiciones de los embalses, por ejemplo, la temperatura.

A continuación, se muestra un ejemplo de los datos que proporciona la CONAGUA para un sitio de muestreo:

Tabla 3.2 Resultados del monitoreo en la Cortina Presa Valle De Bravo

Cortina: Presa Valle de Bravo						
Coordenada de muestreo	Fecha Realización	Año	SST (mg/L)	Secchi (m)	Clorof_A (mg/m ³)	Temp_Agua_Sup (°C)
19.2078,-100.1801	19/11/2012	2012	<10	0.400	258.560	23.070
19.2078,-100.1801	20/05/2013	2013	10.00	3.000	77.999	23.090
19.2078,-100.1801	11/09/2013	2013	14.00	1.500	343.836	22.900
19.2078,-100.1801	30/01/2014	2014	14.00	2.100	21.310	19.220
19.2078,-100.1801	13/03/2016	2016	10.00	0.600	28.753	18.200
19.2078,-100.1801	03/08/2016	2016	16.00	0.500	74.888	24.500
19.2078,-100.1801	20/03/2017	2017	<10	0.550	16.172	20.500
19.2078,-100.1801	22/09/2017	2017	10.00	0.690	4.354	25.400
19.2078,-100.1801	26/04/2018	2018	26.00	0.500	8.756	23.700
19.2078,-100.1801	19/07/2018	2018	20.66	0.200	25.683	23.300
19.2078,-100.1801	30/11/2018	2018	<10	0.500	7.110	20.100
19.2078,-100.1801	25/10/2019	2019	12.50	0.500	8.058	21.500

Fuente: <https://www.gob.mx/conagua>.

Para el sitio de interés la CONAGUA reporta 6 sitios de muestro asociados a las siguientes coordenadas:

Tabla 3.3 Sitios de muestreo en la presa Valle de Bravo.

Sitio	Nombre del sitio	Coordenadas	
		Latitud	Longitud
1	CORTINA PRESA VALLE DE BRAVO	19.20780	-100.18010
2	PRESA VALLE DE BRAVO 1	19.20450	-100.17480
3	PRESA VALLE DE BRAVO 2	19.18070	-100.15940
4	PRESA VALLE DE BRAVO 3	19.19400	-100.15190
5	PRESA VALLE DE BRAVO 4	19.21470	-100.14950
6	PRESA VALLE DE BRAVO 5	19.18000	-100.13510

Fuente: <https://www.gob.mx/conagua>.

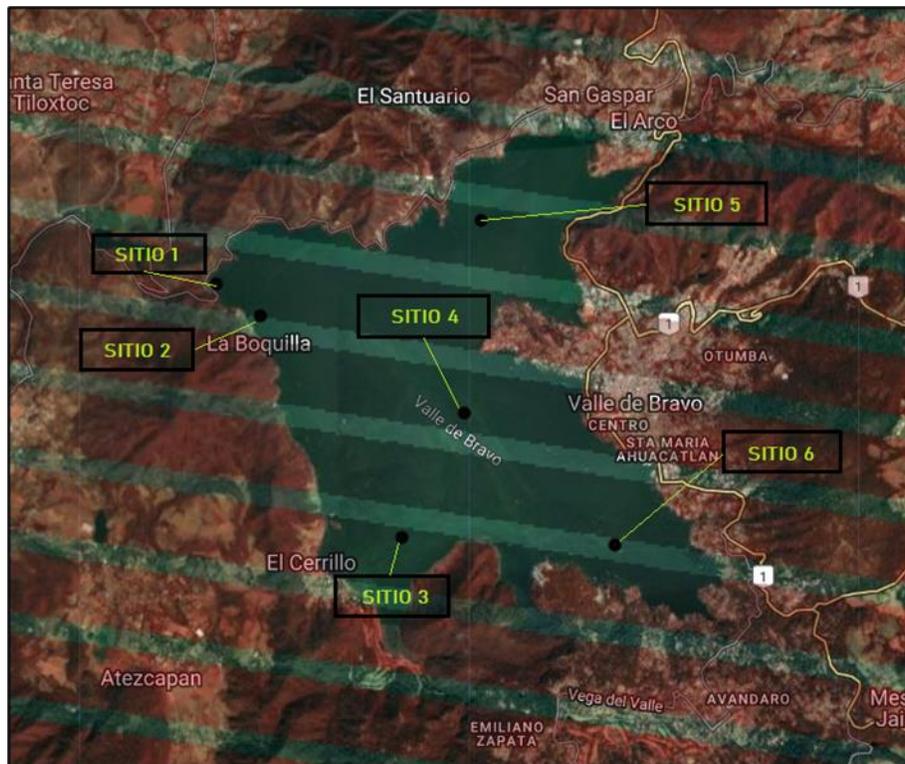


Figura 3.4 Puntos de muestreo, sobre imagen Landsat 7, fuente: <https://earthengine.google.com/>.

Los sitios de muestreo anteriores arrojan 84 datos con diversas fechas que van desde 2012 hasta 2019.

Posteriormente se localizaron las imágenes de Landsat 7 y 8 de la colección 2, en nivel 2, cuyas imágenes contenidas fueron procesadas para proporcionar valores de reflectancias en escala de 16 bits.



El criterio de búsqueda fue que las imágenes coincidentes a los puntos de muestro estuviesen cercanas a las fechas de muestreo con una tolerancia de +/-1 día de diferencia entre el paso del satélite y el día reportado de la exploración.

Como resultado de la búsqueda anterior se localizaron 8 datos de imágenes Landsat 7 en los puntos 1,3, 4,5 y 6.

Tabla 3.4. Valores de reflectancias para los sitios de la presa Valle de Bravo.

Sitio	Bandas						Fecha
	Azul	Verde	Infrarrojo cercano	Rojo	Infrarrojo de onda corta 1	Infrarrojo de onda corta 2	
1	8357	9251	9295	8390	7736	7464	30/01/2014
1	9824	10207	9804	9840	9075	8862	20/05/2013
2	10242	12183	10564	10744	9569	9257	19/07/2018
3	10297	12174	10283	10745	9570	9256	19/07/2018
4	8211	8927	7730	8020	7252	7362	29/01/2014
4	10342	12328	10897	10866	9574	9168	19/07/2018
5	10124	11576	10542	10584	9564	9000	19/07/2018

Fuente: Reflectancias extraídas de imágenes Landsat 7 obtenidas en <https://earthengine.google.com>.

Como consecuencia de la escasez de datos y fechas de muestreo fue necesario localizar información de diversos cuerpos de agua que presentaron similitudes con el embalse de Valle de Bravo, el criterio de la elección fue que tuvieran una climatología similar.

Los embalses elegidos fueron:

- Presa Villa Victoria. Ubicada igualmente en la cuenca Amanalco Valle de Bravo, es uno de los embalses primordiales que suministran al Sistema Cutzamala. Cuenta con una capacidad estimada de 185.7 hm³, la profundidad máxima del embalse se estima de 18 metros, un espejo de agua de 27.57 km² y un perímetro de 60.9 km (Red Mexicana de Cuencas, 2023).
- Presa Guadalupe. Ubicada en el Estado de México en el municipio de Cuautitlán Izcalli, forma parte de la cuenca Río Moctezuma y es utilizada como fuente de agua potable. Su extensión aproximada es de 50 km² y el



espejo de agua cubre una superficie de 4.5 km², la profundidad máxima es de casi 40 metros en el centro y el clima es del tipo cálido subhúmedo con temperaturas variables entre 19 y 25°C (Aguirre, 2015).

- Lago de Chapala. Ubicado en la cuenca Lerma-Santiago el cual incluye siete estados de la República Mexicana, catalogado como el lago más grande del país, posee un área inundada de 7.35 km², con 82.18 km de longitud máxima, anchura promedio de 18.8 km y una superficie de 1740.8 km². El clima es templado, oscila entre los 19 y 35° C y es la principal fuente de abastecimiento de agua potable para la Zona Conurbada de Guadalajara (Medio Ambiente y Desarrollo Territorial, 2014).
- Presa La Villita. Mejor conocida como Presa José Morelos y Pavón, está situada sobre el cauce del Río Balsas. Se encuentra entre los municipios de Isidoro Montes de Oca en el estado de Guerrero y de Lázaro Cárdenas en Michoacán, es utilizada principalmente para generación hidroeléctrica. La longitud de la línea de conducción es de 3.999 km, posee un clima del tipo cálido subhúmedo con temperaturas mínimas de 25.9°C y máximas de 28.7°C (IMCYC, 2011).
- Presa Manuel Ávila Camacho. Esta presa fue construida durante el periodo de 1941 a 1946 con el propósito principal de controlar el flujo de agua en el Río Atoyac a 22 kilómetros al sureste de la Ciudad de Puebla, en el municipio de Totimehuacán. Con una superficie de 2,595, longitud máxima de 17.2 km, ancho máximo de 9.2 km y una profundidad máxima de 32 m (según datos tomados en 1970), el clima mayormente es del tipo templado subhúmedo con temperaturas anuales de 16.6°C (media), 21.3°C (máxima) y de 10.8°C como temperatura mínima (SEMARNAT, s.f.).
- Presa Atlangatepec. Esta presa se encuentra en el estado de Tlaxcala en el municipio con el mismo nombre. Abastecida principalmente por el río Zahuapan y construida en 1963, contaba con una capacidad inicial de 54.5 millones de metros cúbicos y un área de 1,200 ha, el clima predominante en la región es del tipo templado subhúmedo, con una temperatura promedio media anual de 20.7°C (Flores, 2005).



Los datos obtenidos para Landsat 7 y 8 se muestran a continuación:

Tabla 3.5 Valores de reflectancia para diversos puntos de muestreo.

Bandas						Coordenadas						
1	2	4	3	5	7	Temp (°C)	Secchi (m)	SST (mg/L)	Clorof_A (mg/m ³)	Fecha del Muestreo	Lat	long
8357	9251	9295	8390	7736	7464	19.22	2.1	14	21.31	30/01/2014	19.2078	-100.1801
9824	10207	9804	9840	9075	8862	23.09	3	10	77.999	20/05/2013	19.2078	-100.1801
8211	8927	7730	8020	7252	7362	19.66	2	14	2.92	29/01/2014	19.2147	-100.1495
10342	12328	10897	10866	9574	9168	24.4	0.2	54	19.6472	19/07/2018	19.2147	-100.1495
10297	12174	10283	10745	9570	9256	23.5	0.2	NULL	11.2764	19/07/2018	19.1940	-100.1519
10242	12183	10564	10744	9569	9257	23.5	0.2	16.87	8.818	19/07/2018	19.1807	-100.1594
65535	65535	33641	65535	65535	31633	15.8	0.8	NULL	1.2721	26/12/2012	19.46325	-99.99544
10124	11576	10542	10584	9564	9000	23.5	0.2	13.5	10.0456	19/07/2018	19.18000	-100.1351
9243	9535	11542	9529	11923	10394	17.4	0.41	12	27.5492	13/03/2018	20.04692	-99.69695
8374	8372	7986	8187	7632	7587	18.1	0.4	14	15.49	31/03/2015	19.6234	-99.2499
8474	8276	8009	8097	7561	7425	17.9	0.3	14	31.83	31/03/2015	19.63001	-99.25723
8283	8462	8264	8147	7558	7506	18	0.4	12	41.16	31/03/2015	19.63405	-99.25247
8475	8606	8142	8217	7642	7425	17.6	0.3	16	23.34	31/03/2015	19.63323	-99.26012
8818	9102	9708	8555	8333	7983	31.2	2	NULL	3.13	14/06/2014	18.11645	-102.1838
10208	10833	8998	10582	7473	7429	21.4	0.28	70	0	02/12/2012	20.1586	-102.7732
10294	11293	10527	11843	8394	8234	24.3	0.3	256.67	0	06/04/2015	20.1586	-102.7732
10068	10665	9010	10869	7721	7506	22.9	0.2	10.5	0.474	30/10/2018	20.1586	-102.7732
9443	10063	8230	9857	7406	7438	21.9	0.34	20	14.935	19/02/2019	20.1586	-102.7732
11047	11693	10295	11597	8637	8515	20.5	0.8853	156.66 67	2.1	08/12/2012	20.17141	-102.8043
10364	11232	10268	11846	8078	7987	24.1	0.3	76.67	0	06/04/2015	20.17141	-102.8043
9490	10092	8256	9810	7324	7347	21	0.4	29.55	18.166	19/02/2019	20.17141	-102.8043
10597	11563	10532	11967	8397	8318	23.1	0.4	36.67	0	06/04/2015	20.1739	-102.8701
9682	10738	9914	10006	8378	8039	23.9	0.5	25	16.7052	14/10/2015	20.28698	-103.2485
8160	8342	7628	8019	7308	7556	25	0.42	15.61	8.4444	14/10/2021	20.28698	-103.2485
10230	10903	8310	10260	7561	7315	20.7	0.2	20	0.5	22/11/2012	20.27583	-103.2983
9694	10687	8060	9712	7464	7336	24.6	1	16	0.519	22/04/2015	20.27583	-103.2983
10106	10673	8628	10004	7654	7727	20.9	0.35	13	1.422	07/02/2018	20.28306	-103.1883
9141	10193	7985	9371	7212	7240	26	0.47	26.73	7.2848	13/10/2021	20.28306	-103.1883
10078	10909	8320	10346	7462	7528	19.2	0.3	30	NULL	22/11/2012	20.2722	-103.2436
9636	10749	7933	9769	7464	7257	25.5	0.4	18	1.212	04/05/2017	20.2722	-103.2436
8921	9419	8217	9027	7584	7536	18.8	0.5	16	NULL	08/02/2018	20.2722	-103.2436
9272	10437	8140	9434	7308	7237	25	0.47	17.53	13.2556	13/10/2021	20.2722	-103.2436
9923	10687	8026	9988	7577	7535	20.3	0.3	80	NULL	22/11/2012	20.21178	-103.2356
10358	11145	8577	10483	7593	7438	19.1	0.4	20	NULL	22/11/2012	20.30388	-103.1362



10769	11943	9572	11265	8849	8523	25.6	0.3	36	0.7686	20/04/2015	20.30388	-103.1362
9098	9446	8974	9003	8051	7737	22.5	0.5	NULL	8.944	11/10/2018	18.91068	-98.18208
8396	8245	8184	8171	7657	7334	18.2	0.47	NULL	4.88	24/02/2014	18.90425	-98.16672
8137	8141	7938	8074	7584	7526	16.1	0.9	12	NULL	27/02/2017	18.90425	-98.16672
10885	12821	13433	9203	7442	7176	18.5	0.18	13	0.5	28/10/2013	19.570666	-98.18658
10880	12745	13365	9195	7528	7174	18.5	0.18	13	0.5	28/10/2013	19.570666	-98.18658
8564	8809	8710	8461	8315	8226	19	0.5	16	NULL	03/05/2018	19.570666	-98.18658
8583	9058	8572	8096	7549	7466	17.5	0.59	19	9.949	07/02/2019	19.570666	-98.18658
10757	12537	13107	9203	7442	7455	17.3	0.18	21	0.4	28/10/2013	19.561722	-98.18633
10752	12531	13169	9194	7439	7360	17.3	0.18	21	0.4	28/10/2013	19.561722	-98.18633
9207	10163	9576	8416	7348	7321	19.8	0.54	15	NULL	04/08/2017	19.561722	-98.18633
9161	10129	9549	8389	7337	7316	19.8	0.54	15	NULL	04/08/2017	19.561722	-98.18633
8683	9057	8481	8007	7559	7371	11.5	0.82	NULL	3.12	01/02/2018	19.561722	-98.18633
8463	8754	8601	8468	8317	8307	19.2	0.5	15	5.318	03/05/2018	19.561722	-98.18633
8452	8740	8592	8459	8314	8221	19.2	0.5	15	5.318	03/05/2018	19.561722	-98.18633
8723	9058	8642	8096	7549	7367	17	0.5	14	6.493	07/02/2019	19.561722	-98.18633

Fuente: Reflectancias extraídas de imágenes Landsat 7 obtenidas en <https://earthengine.google.com/>



Tabla 3.6 Valores de reflectancia para diversos puntos de muestreo

Bandas							Coordenadas						
1	2	3	5	4	6	7	Temp (°C)	Secchi (m)	SST (mg/L)	Clorof_A (mg/m ³)	Fecha del Muestreo	Lat	long
9390	10158	11976	9854	11666	9340	9179	22.9	0.6	54	11.6052	14/08/2013	19.45822	-99.99081
7725	8401	10206	8099	9993	7349	7331	23	0.4	64	4.3299	14/08/2013	19.46325	-99.99544
7767	8465	10129	8102	9883	7512	7455	22.9	0.7	30	14.7036	14/08/2013	19.45484	-99.99575
7384	7883	9096	7742	8923	7410	7287	23	0.4	30	3.0269	14/08/2013	19.46159	-100.0547
7287	7806	8997	7862	8502	7811	7753	16.5	0.41	60	26.0625	20/02/2019	19.45822	-99.99081
7152	7641	8752	7588	8217	7527	7504	16.4	0.97	32	27.5844	20/02/2019	19.46325	-99.99544
7063	7540	8674	7488	8087	7463	7436	16.2	0.33	56	18.2027	20/02/2019	19.45484	-99.99575
6860	7242	8016	7416	7707	7458	7491	15.1	1.53	36	17.4808	20/02/2019	19.46159	-100.0547
9077	9517	10917	15879	11133	14584	12440	15.2	0.3	NULL	5.5256	17/03/2016	19.21598	-100.1949
8425	8708	9435	8300	8866	7822	7746	23.1	0.3	14	72.2563	18/04/2013	19.6234	-99.2499
7963	8256	9024	8075	8524	7742	7687	22.1	0.45	NULL	53.4654	18/04/2013	19.63001	-99.25723
8165	8451	9075	8271	8661	7901	7820	22.9	0.4	24	34.1016	18/04/2013	19.63405	-99.25247
8455	8677	9273	8385	8798	7913	7809	21.3	0.3	16	23.34	18/04/2013	19.63323	-99.26012
7228	7370	7787	7560	7397	7438	7391	30.6	1.3	NULL	2.82	22/06/2014	18.04874	-102.1813
7781	7936	8369	7964	8013	7618	7485	31.4	1	NULL	2.37	25/07/2018	18.05757	-102.1903
7291	7388	7774	7537	7345	7441	7402	31	2	NULL	5.42	21/06/2014	18.13686	-102.1706
9315	10011	12607	9160	13933	7891	7685	15	0.18	NULL	1.52	25/01/2018	19.60348	-101.2835
9232	9713	10655	9344	10868	7780	7628	23.4	0.25	107.5	46.35	24/02/2014	20.1586	-102.7732
9288	9799	10743	9379	11028	7573	7472	24.3	0.3	256.67	0	06/04/2015	20.1586	-102.7732
8790	9420	10624	8425	10863	7659	7576	22.9	0.2	10.5	0.474	30/10/2018	20.1586	-102.7732
7872	8515	9946	7636	9515	7384	7405	21.9	0.34	20	14.935	19/02/2019	20.1586	-102.7732
8163	8886	10425	8819	10817	7578	7573	24.3	0.3	275	9.002	17/10/2013	20.17141	-102.8043
8707	9412	11175	10232	12023	7855	7867	22.8	0.2	160	36	17/09/2014	20.17141	-102.8043
8460	9181	10571	8697	10834	7476	7444	24.1	0.3	76.67	0	06/04/2015	20.17141	-102.8043
8208	8882	10369	8543	10714	7823	7753	22.6	0.2	11.5	0	30/10/2018	20.17141	-102.8043
8209	8805	10156	7754	9760	7448	7459	22.6	0.4	29.55	18.166	19/02/2019	20.17141	-102.8043
7677	8473	10327	8858	10789	7486	7562	23.6	0.3	72.5	0	17/10/2013	20.1739	-102.8701
8650	9266	10695	8691	10935	7957	7888	23.7	0.2	11.5	0	30/10/2018	20.1739	-102.8701
8014	8681	9989	7611	9634	7391	7421	21.4	0.32	24.44	7.11	19/02/2019	20.1739	-102.8701
10637	11051	11968	9821	11485	9179	8895	27.8	0.35	13	1.1397	04/05/2017	20.28698	-103.2485
7733	8423	9999	6997	8810	7222	7346	25.8	0.5	82.5	12.0712	19/08/2015	20.27583	-103.2983
8723	9717	11637	9775	10918	8894	8630	24.3	0.4	19.5	2.37	07/10/2016	20.27583	-103.2983
9705	10254	11496	9981	11124	8855	8530	25.8	0.3	37.14	34.365	07/10/2016	20.28306	-103.1883
10586	11048	11976	9621	11406	9114	8853	25.4	0.45	22.5	NULL	05/05/2017	20.28306	-103.1883
7657	8313	9862	7152	8769	7359	7405	25.7	0.5	30	7.9252	19/08/2015	20.2722	-103.2436
10665	11127	12117	9654	11517	9180	8954	24.8	0.37	11	1.3791	07/10/2016	20.2722	-103.2436
8001	8507	9932	7226	8780	7232	7306	24.5	0.5	58	10.24	19/08/2015	20.21178	-103.2356



7504	8229	10041	7494	9276	7939	7976	22	0.37	13	1.2509	04/05/2017	20.21178	-103.2356
7541	8401	10205	7373	9094	7890	7952	25	0.5	16.5	1.7664	26/07/2018	20.21178	-103.2356
8288	8970	10674	8073	9885	8051	8025	28.5	0.5	22	9.7012	19/08/2015	20.30388	-103.1362
10412	10941	12023	9851	11450	9429	9117	24.6	0.5	32.5	NULL	05/05/2017	20.30388	-103.1362
8796	9267	10258	7879	9871	7437	7385	25	0.45	12.5	3.318	31/10/2018	20.30388	-103.1362
7410	8052	9669	7124	8881	7204	7278	22.1	0.3	NULL	NULL	20/02/2019	20.30388	-103.1362
10579	11094	12057	9860	11512	9516	9205	25.5	0.24	14.5	0.5	28/08/2017	20.3079	-103.1042
8794	9307	10301	7938	9796	7487	7436	25.4	0.6	13.5	5.1524	31/10/2018	20.3079	-103.1042
7519	8238	9685	7064	9032	7203	7267	21.6	0.3	17	0.5	20/02/2019	20.3079	-103.1042
9094	9568	11405	12090	10230	8889	8219	26.4	0.5	450	25.8708	18/08/2015	20.31895	-103.0468
10786	11250	12181	10165	11732	9734	9363	26.9	0.41	88	3.1239	03/05/2017	20.31895	-103.0468
9366	9712	10505	8019	9984	7505	7441	24.2	0.4	20	11.9512	31/10/2018	20.31895	-103.0468
7419	8123	9767	7071	8947	7199	7278	21.6	0.3	18.5	0.5	20/02/2019	20.31895	-103.0468
8220	8897	10636	8162	9744	8078	8069	25.5	0.3	168.57	20.0672	18/08/2015	20.3	-102.95
10686	11212	12156	10150	11835	9715	9410	23.7	0.51	35.33	1.823	03/05/2017	20.3	-102.95
8589	9128	10226	7795	9734	7485	7457	22.3	0.5	10	1.896	31/10/2018	20.3	-102.95
7441	8199	9665	7098	9068	7194	7270	20.6	0.32	50.77	0.5	20/02/2019	20.3	-102.95
9205	10178	11924	11310	11418	9625	9196	24.4	0.4	29	1.185	07/10/2016	20.28649	-103.355
10231	10734	11644	9461	11214	8903	8666	25	0.38	17	4.2831	04/05/2017	20.28649	-103.355
10147	10678	11624	9289	11093	8761	8552	25.6	0.37	16.5	1.9069	04/05/2017	20.27906	-103.399
7636	8343	9858	6927	8807	7151	7284	25	0.3	153.33	10.1752	19/08/2015	20.27767	-103.342
9590	10442	11940	10631	11373	9226	8877	25.3	0.4	98.57	2.7208	07/10/2016	20.27767	-103.342
10673	11062	11954	9668	11451	9098	8814	25.3	0.35	26	0.9701	04/05/2017	20.27767	-103.342
7547	8281	10170	7778	9287	7907	7940	24.7	0.3	33.75	21.5336	18/08/2015	20.25137	-102.9739
10852	11322	11290	10293	11935	9836	9503	23.3	0.47	67.14	4.384	03/05/2017	20.25137	-102.9739
7517	8194	9551	7069	9113	7239	7322	21.8	0.5	15.5	0.948	31/10/2018	20.25137	-102.9739
7571	8296	9689	7145	9235	7224	7304	20.6	0.4	33.13	0.5	20/02/2019	20.25137	-102.9739
8034	8475	9445	9173	8224	7521	7425	16.5	0.35	12	NULL	02/01/2018	18.91068	-98.18208
8080	8220	8979	8629	18827	12365	9881	20.5	0.5	11	4.004	06/02/2019	18.91068	-98.18208
7713	7854	8134	7944	7916	7630	7521	18.2	0.47	NULL	4.88	24/02/2014	18.90425	-98.16672
8116	8279	8734	8387	7880	7485	7412	18.9	0.4	24	24.34	02/01/2018	18.90425	-98.16672
7605	7711	7854	7597	7514	7470	7456	20.1	0.46	12	4.606	06/02/2019	18.90425	-98.16672
12192	13302	15275	15852	12273	11033	10544	18.2	0.23	42	4.33	21/05/2013	19.57066	-98.18658
8247	9053	14045	14627	14202	13065	12592	13.4	0.3	68	NULL	05/02/2016	19.57066	-98.18658
8681	9145	10806	10476	11791	11386	11308	19	0.5	16	NULL	03/05/2018	19.57066	-98.18658
12009	12979	14950	14661	12590	11281	10743	18.07	0.23	24	4.81	21/05/2013	19.56172	-98.18633
7372	7872	8739	8388	7616	7468	7429	17	0.5	14	6.493	07/02/2019	19.56172	-98.18633

Fuente: Reflectancias extraídas de imágenes Landsat 8 obtenidas en <https://earthengine.google.com/>



Con el fin de aumentar el volumen de datos y que exista congruencia entre ellos, se omite el uso de la banda 1 de Landsat 8, es decir, se utilizan las bandas: azul, verde, roja, infrarrojo cercano e infrarrojos de onda corta.

Adicionalmente a los valores extraídos de los muestreos reportados por CONAGUA, se extrajeron 75 datos de la Tesis *Diseño de modelos de calidad del agua mediante el uso de la percepción remota* (Sepúlveda, 2011), los cuales contienen datos de profundidad del Disco Secchi y Sólidos Suspendidos Totales. Dichos muestreos fueron extraídos de la presa Valle de Bravo el 10 de octubre y el 24 de abril del 2010 y finalmente la muestra de datos contiene un total de 200 observaciones.

Los valores de TSI fueron calculados a partir de la profundidad del disco Secchi como es descrito en la ecuación del capítulo 3.3.

Tabla 3.7 Valores de TSI obtenidos de la Profundidad de Disco Secchi en los diversos puntos de muestreo

Num	Bandas						Temp (°C)	Secchi (m)	SST (mg/L)	TSI (mg/m ³)	Clorof_A
	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2					
1	8427	8819	7841	8123	7551	7505	22.42	1.97	1	50.22	N/A
2	8339	8900	7844	8132	7550	7590	22.26	2.03	0	49.79	N/A
3	8448	8893	8113	8309	7716	7590	22.03	1.57	24	53.49	N/A
4	8309	8822	7705	8125	7469	7335	22.27	1.86	1	51.05	N/A
5	8802	8766	7710	7950	7388	7506	22.44	1.88	1	50.89	N/A
6	8071	8633	7576	7950	7306	7506	22.4	1.74	15	52.01	N/A
7	8509	8767	7851	8198	7555	7592	22.34	1.96	15	50.29	N/A
8	8466	8912	7862	8090	7559	7593	22.3	1.82	9	51.36	N/A
9	8458	8840	7857	8144	7558	7507	22.43	1.83	9	51.28	N/A
10	8508	8767	7852	8076	7638	7337	22.39	1.71	27	52.26	N/A
11	8324	8638	7580	7955	7390	7252	22.42	1.78	12	51.68	N/A
...											
193	8279	8734	7880	8387	7485	7412	18.9	0.4	24	73.22	24.34
194	7711	7854	7514	7597	7470	7456	20.1	0.46	12	71.20	4.606
195	13302	15275	12273	15852	11033	10544	18.2	0.23	42	81.20	4.33
196	9053	14045	14202	14627	13065	12592	13.4	0.3	68	77.37	NULL
197	9145	10806	11791	10476	11386	11308	19	0.5	16	70.00	NULL
198	12979	14950	12590	14661	11281	10743	18.07	0.23	24	81.20	4.81
199	7872	8739	7616	8388	7468	7429	17	0.5	14	70.00	6.493
200	7744	8589	7275	8077	7379	7406	17	0.44	17	71.84	49.92

Fuente: Elaboración propia.



3.5 Modelos

3.5.1 Análisis de correlación

La correlación es una medida normalizada que describe la relación lineal entre dos variables cuantitativas continuas, esta medida o índice de correlación puede variar entre -1 y +1 indicando correlaciones positivas o negativas. Una correlación positiva indica que las variables varían en el mismo sentido, una correlación negativa indica que la variación es en sentido opuesto, por su parte, un valor de correlación igual con 0 indica que no existe relación lineal entre variables (Vinuesa, 2016).

Cabe mencionar que el índice de correlación (r) es en sí mismo una medida del efecto, el cual suele interpretarse de la siguiente manera:

1. Correlación despreciable: $r < |0.1|$
2. Correlación baja: $|0.1| < r \leq |0.3|$
3. Correlación media: $|0.3| < r \leq |0.5|$
4. Correlación alta: $r > |0.5|$

Con el propósito de observar las bandas que influyen en mayor medida para cada parámetro de calidad de la muestra de datos (Secchi, Chl_a, SST y TSI), se realizaron análisis de correlación. Los resultados se muestran a continuación:

Para Clorofila Alfa, tomando un total de 92 datos a partir de discriminar los valores nulos:

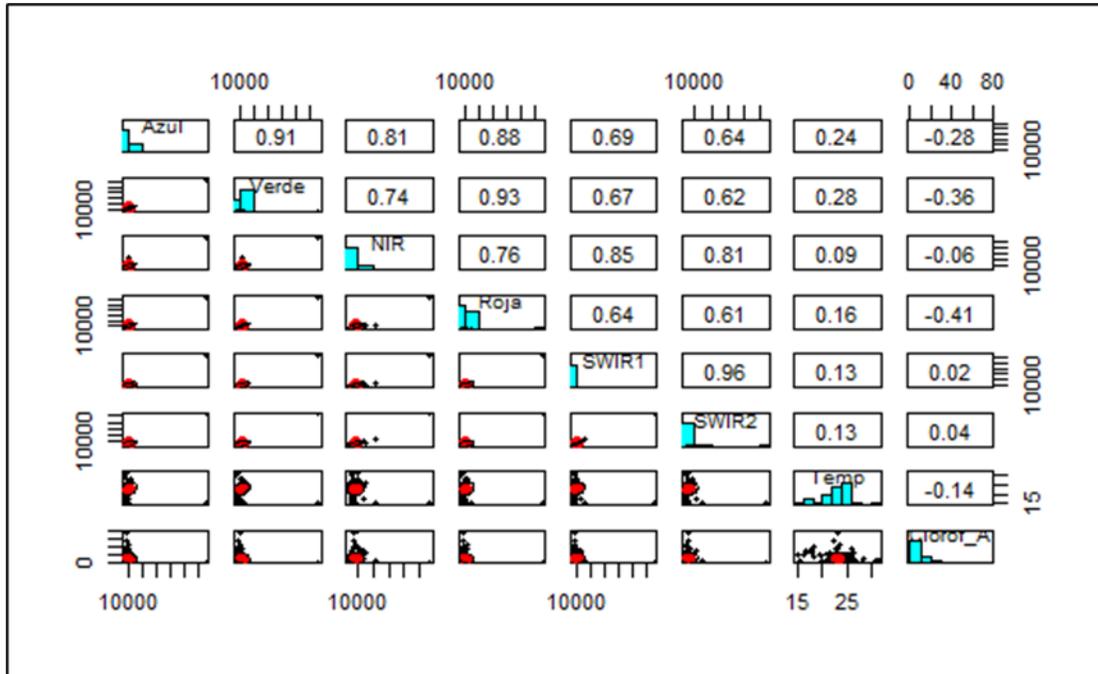


Figura 3.5 Correlación de Clorof_A con bandas Azul, Verde, NIR, Roja, SWIR 1, SWIR 2 y temperatura.

Para SST, tomando una muestra efectiva de 126 datos omitiendo valores nulos:

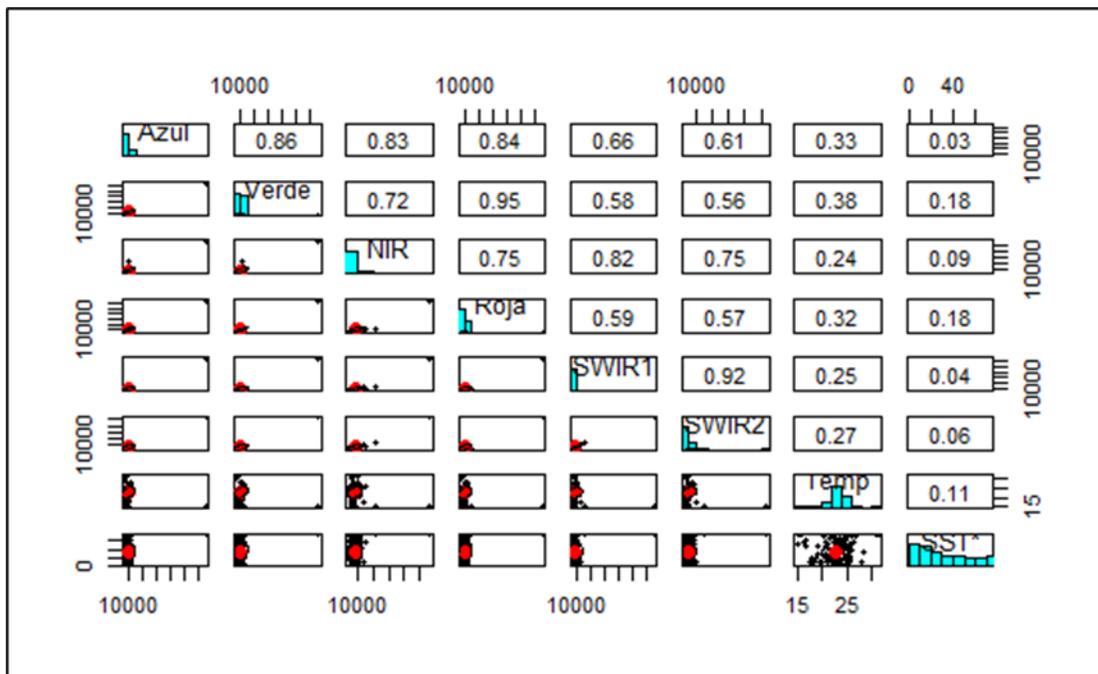


Figura 3.6 Correlación de SST con bandas Azul, Verde, NIR, Roja, SWIR 1, SWIR 2 y temperatura.

Para los datos de profundidad del Disco de Secchi (tomando la muestra completa):

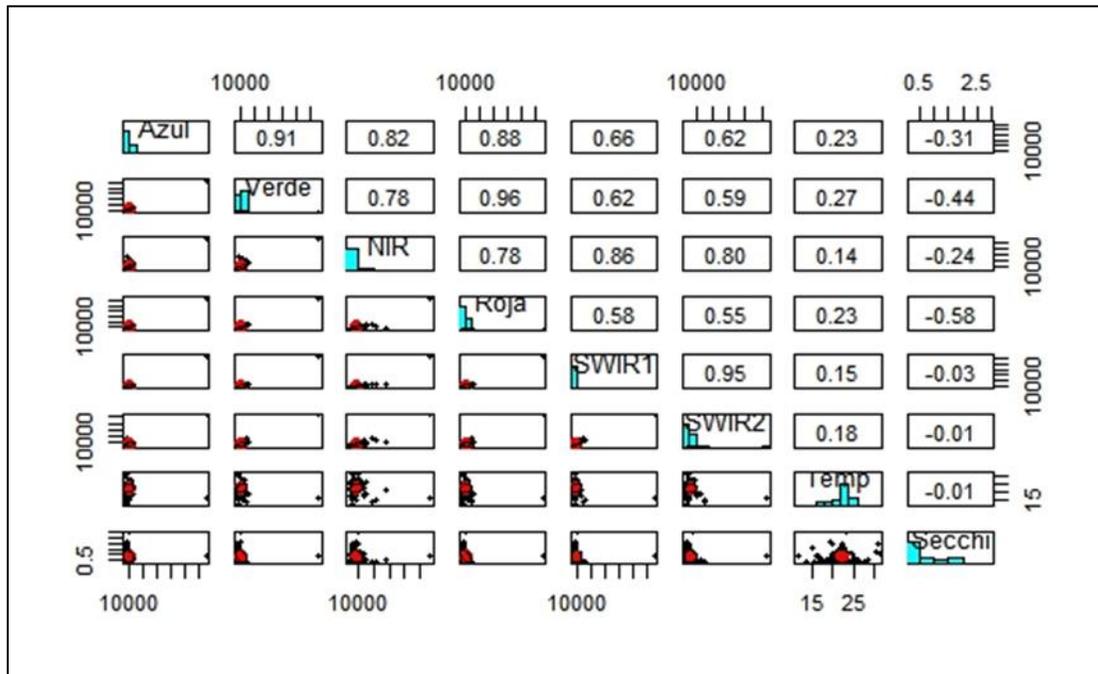


Figura 3.7 Correlación de PDS con bandas Azul, Verde, NIR, Roja, SWIR 1, SWIR 2 y temperatura

Para los valores de TSI:

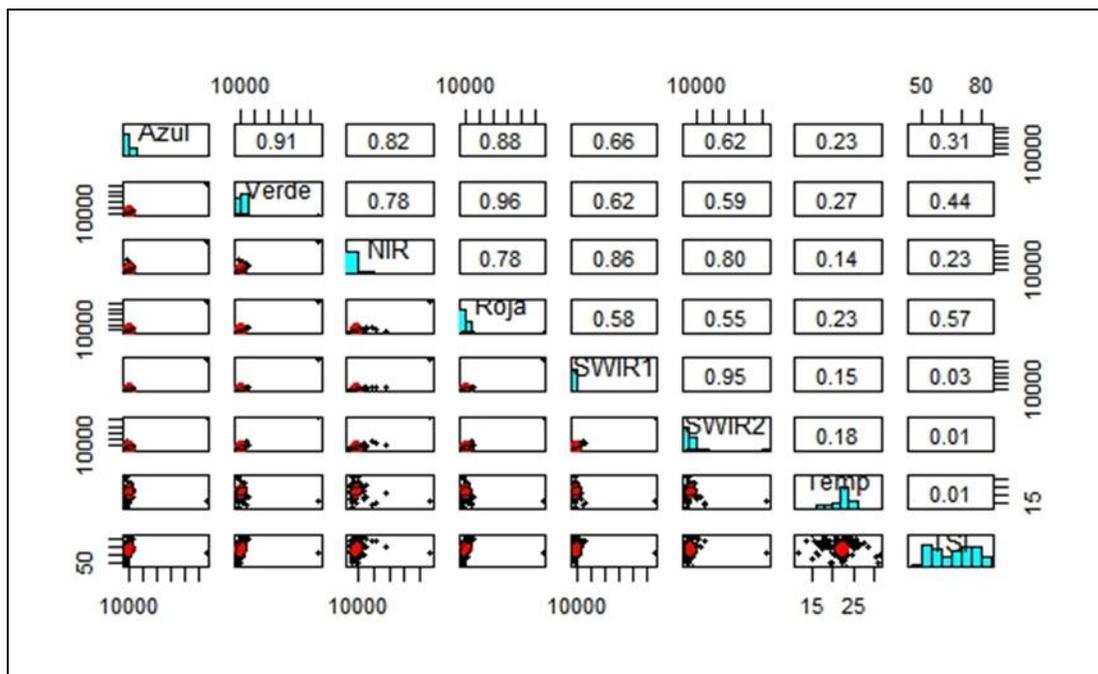


Figura 3.8 Correlación de TSI con bandas Azul, Verde, NIR, Roja, SWIR 1, SWIR 2 y temperatura



Como puede observarse las bandas más representativas para las muestras de Clorofila Alfa, fueron la roja con una correlación media de -0.41, y la banda verde con -0.36. Además se observaron correlaciones bajas para la banda azul y para la temperatura con valores de -0.28 y -0.14, respectivamente.

En el caso del Disco Secchi y el TSI, la banda más representativa fue la roja con una correlación alta de 0.57, de la misma forma, se observaron correlaciones medias en las bandas azul, verde y NIR con 0.31, 0.44 y 0.23, así como, valores bajos para SWIR 1, SWIR2 y temperatura de 0.03, 0.01 y 0.01 (con valores de correlación negativa para la profundidad del Disco de Secchi y positiva para los valores de TSI).

Para el caso de las muestras de SST, los valores de correlación no se identificaron como representativos, por lo cual se excluyen del caso de estudio.

3.5.2 Redes neuronales

Las redes neuronales artificiales son modelos computacionales que intentan imitar el funcionamiento del cerebro humano teniendo como unidad principal de procesamiento la neurona inspirada en la célula principal del sistema nervioso.

Estos modelos son capaces de adquirir conocimiento a través de la experiencia. El funcionamiento de ellos se basa en entradas o *inputs* que llegan a diversas capas de nodos o neuronas que a su vez se encuentran interconectadas como si se tratara de un axón, cada uno de estos axones poseen diversos pesos que son procesados a través de una función de activación o ignorados de acuerdo con cuán representativos sean, es decir, las conexiones con mayor peso son retransmitidas caso contrario a las de menor valor.

El aprendizaje de las redes neuronales se logra mediante el entrenamiento, el cual consiste en procesar un conjunto de datos de entrada o conjunto de entrenamiento con el fin de proporcionar una salida. El entrenamiento implica ajustar los pesos de las conexiones de la red para calcular la salida correcta para cada entrada en el conjunto de entrenamiento. Durante el proceso de aprendizaje, la topología de la



red y las funciones de las neuronas no cambian, pero los pesos de las conexiones sí lo hacen.

La mayoría de las aplicaciones de las redes neuronales consisten en realizar reconocimiento de patrones, cuyo proceso es adaptativo, paralelo y no lineal, mostrando una relación compleja entre los *inputs* y las salidas proporcionando respuestas en forma de clasificación o predicción (Matich, 2001).

Los modelos de redes neuronales se desarrollan utilizando lenguajes de programación y frameworks especializados en aprendizaje automático, tal es el caso de R, con bibliotecas como Neuralnet y ANN2.

El lenguaje R es un software de uso libre creado en 1992 por Ross Ihaka y Robert Gentleman el cual surgió a partir de adaptar el lenguaje S. Este lenguaje se ha convertido en uno de los más populares en el ámbito de la estadística, la ciencia de datos y la investigación.

R es un lenguaje de código abierto, es decir, que su código fuente está disponible públicamente y puede ser modificado y distribuido libremente, del mismo modo, permite al usuario escribir sus propias funciones y crear paquetes, lo cual trae como consecuencia que el lenguaje sea altamente extensible.

Entre las características más importantes de R se encuentran la gran capacidad para manipular y transformar datos de manera eficiente, la creación de gráficos y la disponibilidad de una gran cantidad de paquetes interactivos (Santana et al., 2014).

Para el presente trabajo, se utilizó la paquetería ANN2, la cual permitió crear modelos de redes neuronales para clasificación y regresión, permitiendo la detección de anomalías y el uso de diversas funciones de activación facilitando el entrenamiento rápido mediante el aprendizaje de mini lotes (R-Poject, 2022).

Tomando como base los resultados del capítulo anterior, es posible discriminar variables para cada parámetro de estudio, los cuales fueron ensayados en un



modelo de red neuronal, programado en lenguaje R, siendo este mayormente utilizado para el análisis estadístico.

3.6 Calibración y entrenamiento de los modelos

3.6.1 Medidas de evaluación

Una vez definida la arquitectura de la red es necesario realizar modificaciones que se ajusten a las necesidades de cada parámetro en estudio.

Para medir el desempeño de la red y así elegir el mejor arreglo fue necesario hacer una comparativa entre diversos parámetros, tales como:

Coefficiente de determinación o coeficiente de correlación múltiple al cuadrado, el cual es un parámetro descriptivo que sirve para evaluar el grado de ajuste de modelo a los datos, puesto que mide la capacidad predictiva del modelo ajustado, dicho parámetro se puede calcular de la siguiente forma:

$$R^2 = \frac{\text{Varianza Explicada}}{\text{Varianza Total}} = 1 - \frac{\text{Varianza No Explicada}}{\text{Varianza Total}}$$

Este parámetro se mide entre 0 y 1, sin embargo, un modelo que alcance una R^2 igual a uno, significaría que el modelo alcanza un ajuste perfecto y esto sería un caso relativamente improbable.

De igual forma, existen otros dos parámetros para evaluar modelos de predicción o regresión el *MAE* (*Mean Absolute Error*) y el *RMSE* (*Root Mean Squared Error*); el *MAE* calcula la magnitud promedio de los errores de una predicción y se obtiene tomando la media del total de los errores absolutos de los valores observados y las predicciones.

El *RMSE* por su parte, mide la magnitud promedio de los errores al cuadrado de las predicciones, se calcula como la raíz cuadrada de la media de los errores al cuadrado. Un *RMSE* bajo también indica mayor precisión en las predicciones, pero penaliza más los errores grandes que el *MAE*.



El RMSE y MAE se calculan de la siguiente manera:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (Y_{pred} - Y_{obs})^2}$$

Donde:

n : es el número total de puntos de datos en tu conjunto de datos.

y_{pred} : representa las predicciones del modelo.

y_{obs} representa los valores observados o reales.

$$MAE = \sum_{j=1}^n |Y_{pred} - Y_{obs}|$$

Donde:

n : es el número total de puntos de datos en tu conjunto de datos.

y_{pred} : representa las predicciones del modelo.

y_{obs} representa los valores observados o reales.

4 Resultados

4.1 Arquitectura y desempeño

El primer modelo calibrado fue el correspondiente al PDS, los parámetros para el entrenamiento de la red fueron:

```
X_train <- as.matrix(train_nrm[,1:7])
Y_train <- as.matrix(train_nrm[,8])
X_test <- as.matrix(test_nrm[,1:7])
Y_test <- as.matrix(test_nrm[,8])

NN <- neuralnetwork(X_train,Y_train , hidden.layers =c(10,8,2),
  regression = TRUE, standardize = TRUE, activ.functions = "tanh",
  loss.type = "huber",huber.delta =0.4,
  learn.rates = 1e-03,optim.type = "rmsprop", sgd.momentum = 0.9,
  L1 = 0.010,
  L2 = 0.0,

  random.seed =65,
  drop.last = TRUE,
  val.prop = 0.30, n.epochs = 1000, batch.size = 100)
```

Figura 4.1. Arquitectura de red para el modelo de profundidad de Disco Secchi.

En resumen, los parámetros más relevantes en el entrenamiento de la red son los siguientes:

Tabla 4.1. Resumen del arreglo de la Red Neuronal (Modelo Secchi)

Bandas	Azul, Verde, NIR, Roja, Swir 1, Swir 2 y Temperatura
Función de Activación	Tanh
Número de Capas	3
Neuronas por capa	10, 8, 2
Conjunto de entrenamiento	70%
Conjunto de validación	30%
Número de épocas	1,000

Fuente: Elaboración propia

Dicho arreglo resulta con la siguiente curva de comportamiento:

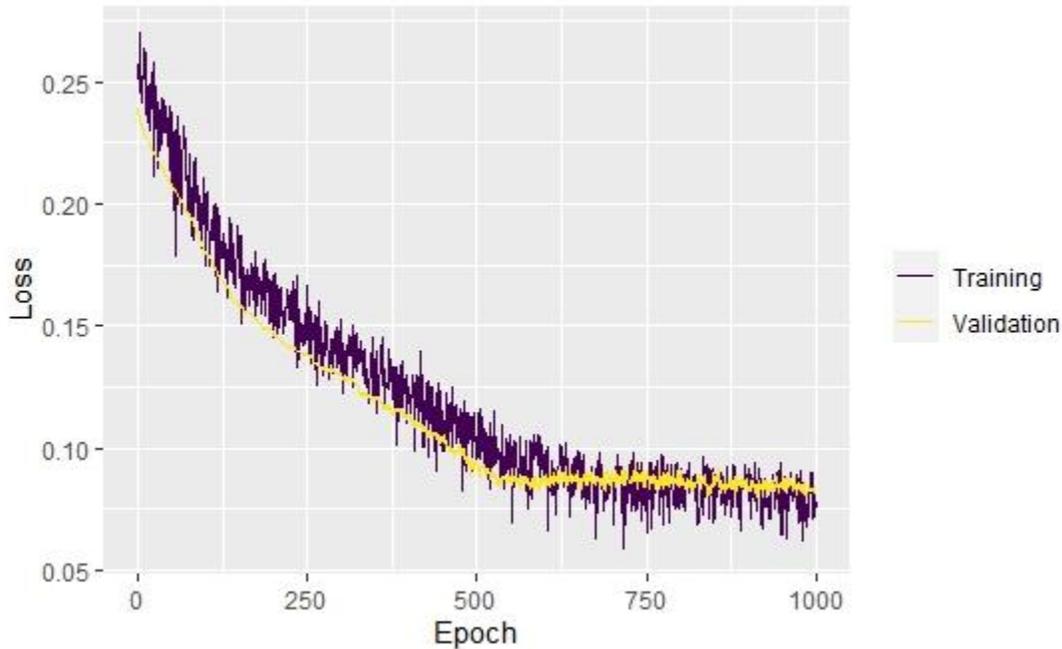


Figura 4.2 Época vs pérdida (Modelo Secchi).

Generalmente las curvas de comportamiento funcionan como una herramienta de diagnóstico para monitorear el comportamiento durante el periodo de aprendizaje de los algoritmos de *Deep Learning*. En la gráfica anterior podemos observar que las variables son *Loss* contra *Epoch*, *Loss* es un valor que indica qué tan bueno o malo resulta el comportamiento de la red después de cada iteración, mientras que las *Epochs* se refieren al número de veces en que los datos pasan por el algoritmo durante el entrenamiento.

Como se ilustra en la Figura 4.2, a partir de la iteración 500 hasta 1000 los valores del conjunto de entrenamiento y validación convergen en los mismos puntos, lo cual indica que el algoritmo es capaz de aprender.

El valor de los parámetros de desempeño resultantes fue:

- ❖ RMSE= 0.290
- ❖ MAE= 0.219
- ❖ $R^2=0.670$

Por otra parte, los valores de la predicción pueden representarse gráficamente en la Figura 4.3:

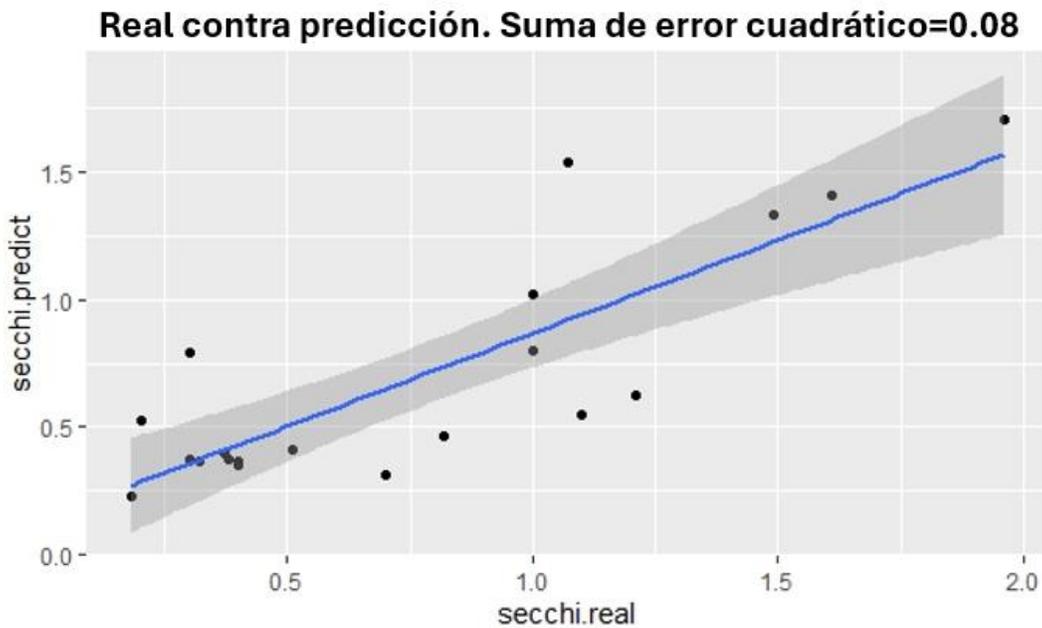


Figura 4.3 Predicción contra valor real (Disco Secchi).

El ajuste para el modelo de índice de estado trófico (TSI) resultó muy similar al utilizado para la predicción de la profundidad del Disco Secchi, siendo la diferencia principal la función de activación.

```
NN <- neuralnetwork(X_train,Y_train , hidden.layers =c(10,8,2),
  regression = TRUE, standardize = TRUE, activ.functions = "relu",
  loss.type = "huber",huber.delta =0.4,
  learn.rates = 1e-03,optim.type = "rmsprop", sgd.momentum = 0.9,
  L1 = 0.010,
  L2 = 0.0,

  random.seed =15,
  drop.last = TRUE,
  val.prop = 0.30, n.epochs = 1500, batch.size = 100)|
```

Figura 4.4. Arquitectura de red para el modelo de profundidad TSI

Los parámetros relevantes son:

Tabla 4.2 Resumen del arreglo de la Red Neuronal (Modelo TSI)

Bandas	Azul, Verde, NIR, Roja, Swir 1, Swir 2 y Temperatura
Función de Activación	ReLU
Número de Capas	3
Neuronas por capa	10, 8, 2
Conjunto de entrenamiento	70%
Conjunto de validación	30%
Número de épocas	1,500

Fuente: Elaboración propia

El valor de los parámetros de desempeño corresponde a:

- RMSE= 5.822
- MAE= 3.708
- $R^2=0.669$

La curva de comportamiento se ilustra en la Figura 4.5:

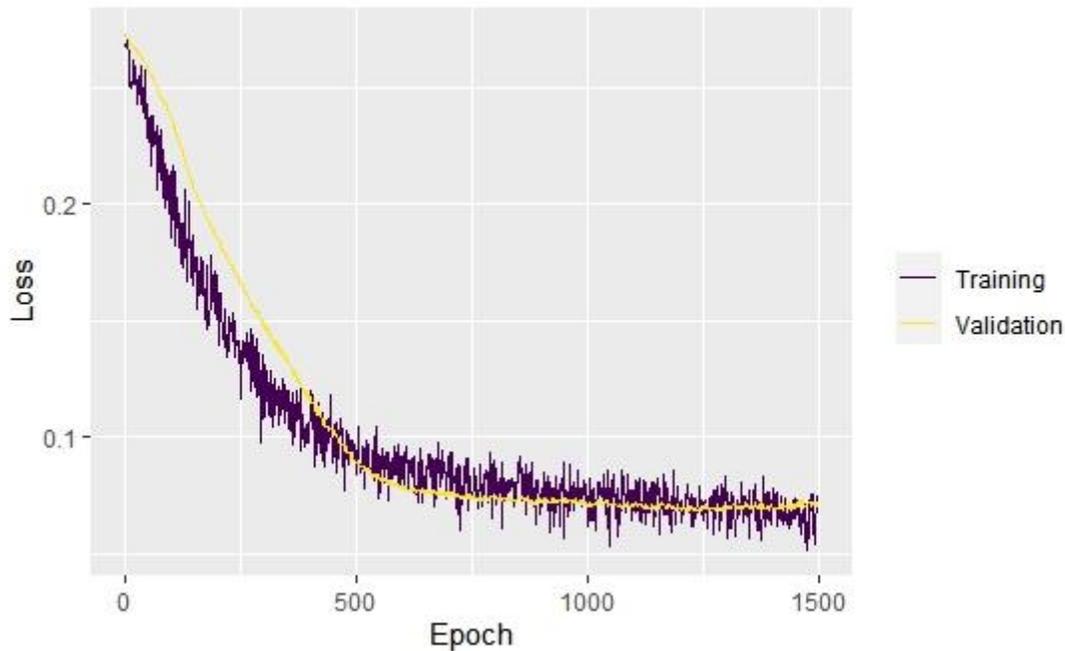


Figura 4.5 Época vs pérdida (Modelo TSI)

La representación gráfica de los valores observados y predichos puede observarse en la Figura 4.6.

Real contra predicción. Suma de error cuadrático=33.9

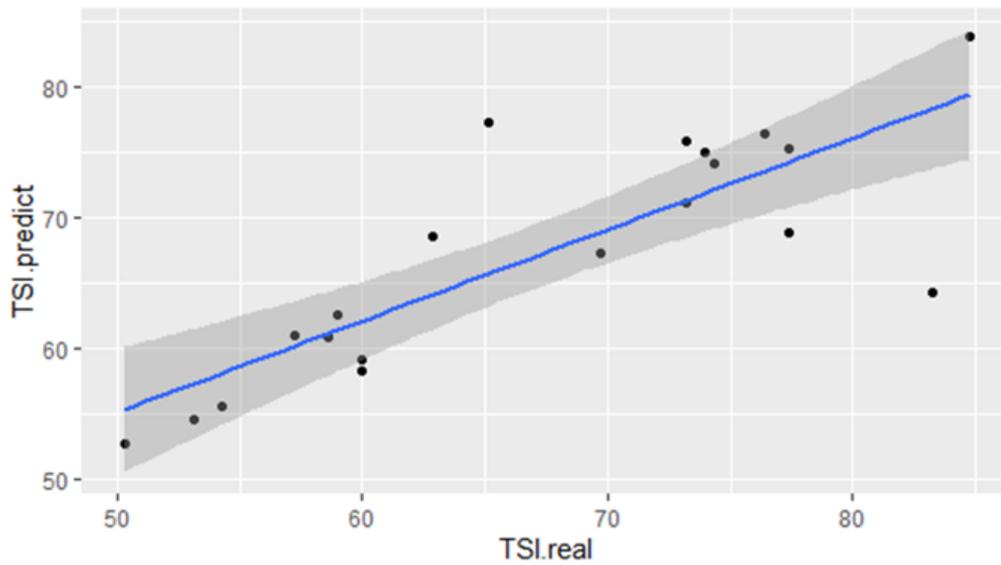


Figura 4.6 Predicción contra valor real (TSI).

Los resultados que arrojan los modelos de predicción se muestran a continuación:

Tabla 4.3. Valores medidos contra valores predichos proporcionados por los arreglos de Red Neuronal.

TSI		PDS (m)	
Observación	Predicción	Observación	Predicción
54.25	55.64	1.49	1.33
50.29	52.71	1.96	1.70
53.13	54.55	1.61	1.41
83.22	64.35	0.20	0.53
77.37	68.87	0.30	0.79
65.15	77.25	0.70	0.31
76.44	76.39	0.32	0.37
73.22	75.86	0.40	0.36
74.34	74.20	0.37	0.40
77.37	75.24	0.30	0.38
73.22	71.19	0.40	0.35
69.71	67.25	0.51	0.41
73.96	75.08	0.38	0.37
59.02	62.62	1.07	1.54
57.25	61.04	1.21	0.62
58.62	60.93	1.10	0.55
60.00	59.14	1.00	0.80
60.00	58.25	1.00	1.02
84.74	83.93	0.18	0.23
62.86	68.63	0.82	0.47

Fuente: Elaboración propia



De los datos anteriores, los muestreos correspondientes a la presa Valle de Bravo se ilustran en la Tabla 4.4:

Tabla 4.4 Predicciones del embalse Valle de Bravo

Parámetros para el entrenamiento							Observación		Predicción		Localización		Fecha
Azul	Verde	NIR	Roja	SWIR1	SWIR2	Temp (°C)	PDS (m)	TSI	PDS (m)	TSI	lat	lon	
8560	9087	8118	8494	7718	7676	22.51	1.49	54.25	1.33	55.64	19.193	-100.140	02/10/10
8322	8810	7883	8117	7485	7596	22.21	1.96	50.29	1.70	52.71	19.212	-100.157	02/10/10
8441	8938	8016	8355	7649	7596	22.62	1.61	53.13	1.41	54.55	19.218	-100.140	02/10/10
10124	11576	10542	10584	9564	9000	23.50	0.20	83.22	0.53	64.35	19.180	-100.135	19/07/18
8918	9514	11467	8990	9472	8918	22.42	1.07	59.02	1.54	62.62	19.172	-100.142	24/04/10
10209	11352	9701	10584	9394	9155	22.13	1.10	58.62	0.55	60.93	19.181	-100.157	24/04/10
10135	11069	9599	10235	9246	8839	22.47	1.00	60.00	0.80	59.14	19.196	-100.148	24/04/10
9825	10668	9241	9918	8790	8838	22.37	1.00	60.00	1.02	58.25	19.212	-100.169	24/04/10

Fuente: Elaboración propia

Con base en el capítulo 3.3 podemos notar que de acuerdo con las observaciones del año 2010, el embalse se encontraba invariablemente en estado mesotrófico cuyas predicciones coinciden con las características del embalse en ese momento. Por su parte para la única observación para los años posteriores la presa se encontraba en estado eutrófico, y aunque la diferencia de la predicción fue relativamente alta el modelo arrojó valores de TSI correspondientes al medido en embalse.

Por su parte, el último modelo calibrado (Clorof_A), no mostró buenos resultados durante el entrenamiento, puesto que la curva se comportó de la siguiente manera:

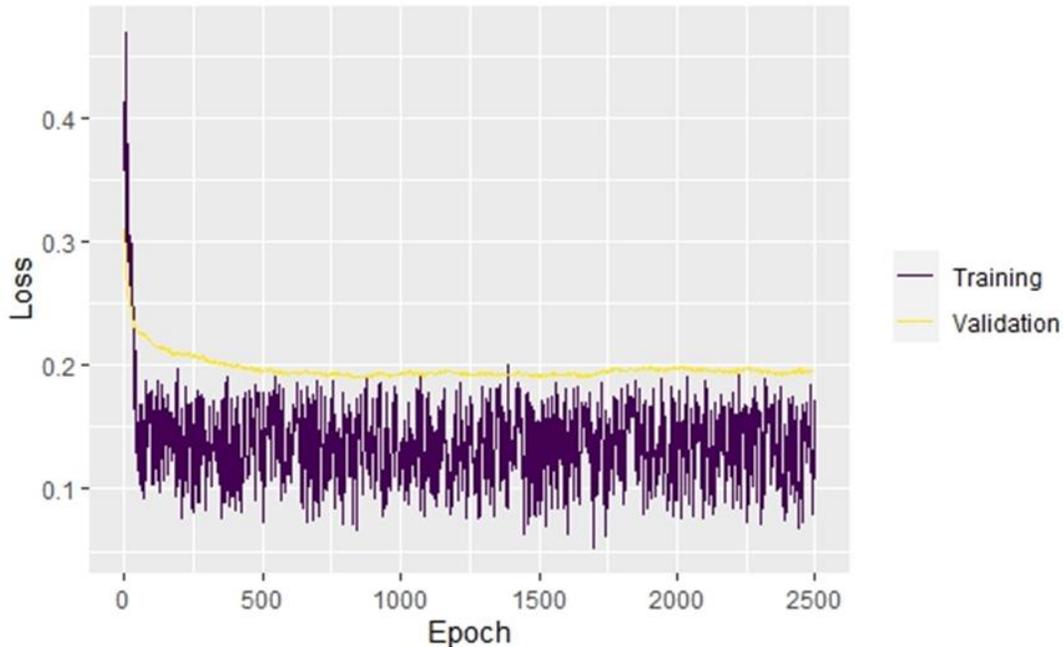


Figura 4.7 Época vs pérdida (Modelo Clorof_A)

Adicionalmente el coeficiente de determinación arrojó un valor igual a 0, lo cual indicó que el modelo no fue compatible con el conjunto de datos.

4.2 Interpretación de resultados

A partir de la recopilación de 200 muestreos de calidad del embalse Valle de Bravo y otros cuerpos de agua con una climatología similar, se formó una matriz de datos en los que incluyeron parámetros como la concentración de Sólidos Suspendidos Totales, Clorofila Alfa, la profundidad del Disco Secchi, la Temperatura y el Índice de Estado Trófico relacionados con imágenes con nula o baja nubosidad asociadas a las coordenadas reportadas al muestreo, proporcionadas por los productos Landsat de la colección 2 y nivel 2 (valores de reflectancia).

Con las imágenes disponibles se extrajeron valores de reflectancia de las bandas Azul, Verde, Roja, NIR (Infrarrojo cercano), SWIR1 y SWIR 2 (Infrarrojos de onda corta) por cada píxel coincidente con los sitios de muestreo.



A partir de lo anterior se realizaron tres modelos de regresión de redes neuronales con ayuda de la paquetería ANN2 en lenguaje R, cuyo objetivo fue realizar predicciones de Clorof_A, PDS y TSI.

En el caso del modelo para Sólidos Suspendidos Totales (SST), se utilizaron solo 126 observaciones de las 200 disponibles porque no todas ellas contenían valores de SST. Los resultados del análisis de correlación para este parámetro arrojaron que ninguna de las bandas estaba relacionada con la concentración de SST, por lo cual, fue descartado del estudio.

En el caso del modelo para la profundidad del Disco Secchi, se apreció que existe correlación alta para la banda roja con valor de 0.57, correlaciones medias en las bandas azul, verde y NIR con 0.31, 0.44 y 0.23, sin embargo, se observaron valores bajos para SWIR 1, SWIR2 y temperatura (0.03, 0.01 y 0.01, respectivamente).

En la parte del entrenamiento, la curva de comportamiento demostró que se necesitan de 500 a 1,000 iteraciones para que el modelo comenzara a aprender. Del mismo modo en la curva se detectó ruido (mayormente en el conjunto de entrenamiento en cada una de las iteraciones), lo cual podría indicar que al modelo le cuesta más trabajar con los datos del entrenamiento que con los datos de la validación. Otra de las posibles causas es que el algoritmo esté cayendo en *overfitting* o sobreajuste, este fenómeno podría suceder debido diversas causas, entre ellas, que los datos del modelo sean escasos o poco representativos, lo cual es esperado debido a la cantidad limitada de información con los que se entrenó el modelo.

Podemos observar que, aunque el coeficiente de determinación indicó que el modelo se ajustó en buena manera al conjunto de observaciones ($R^2=0.67$), las predicciones tuvieron errores recurrentes.

Por su parte para el modelo de predicción de TSI, las correlaciones fueron del mismo valor que en el modelo de PDS (pero inversamente proporcionales). Contrario al modelo PDS se observó que se podrían necesitarse más épocas para que la curva



de comportamiento comenzara a mostrar un posible sobreajuste, sin embargo, el ruido siguió presente en ambos conjuntos (entrenamiento y validación).

Cabe destacar que para que el modelo de TSI tuviera un mejor desempeño fue necesario utilizar ReLU como función de activación. Es importante mencionar que actualmente en la literatura no existen documentos que indiquen la metodología para elegir la función adecuada, comúnmente esta es elegida con base en pruebas y errores (Llano et al., 2007) como sucedió en este trabajo.

Dentro del arreglo del modelo de TSI, se observaron medidas de evaluación con resultados convenientes, tal es el caso de la R^2 con un valor del 0.669, lo cual denota que los datos se adaptaron de forma adecuada sin olvidar que los errores de predicción fueron, en su mayoría, poco representativos, puesto que el TSI corresponde a una medida del tipo clasificatoria donde las variaciones significativas se presentaron en múltiplos de 10 unidades, dicha diferencia ocurrió una vez.

Del mismo modo el modelo predictor de TSI resultó eficaz para estimar el nivel de eutrofización del embalse de interés, por lo cual, éste se percibe como adecuado para su fin.

Finalmente, de los resultados del modelo para la predicción de la Clorof_A se utilizaron únicamente 92 datos que arrojaron que las variables más relacionadas son las bandas Roja y Verde con valores de correlación de -0.41 y -0.36. Por su parte la temperatura y la banda Azul mostraron correlaciones bajas de 0.28 y -0.14, respectivamente. La curva de comportamiento del modelo indicó que probablemente, no se cuenta con la información suficiente para que el algoritmo sea capaz de generalizar las observaciones, debido a que los conjuntos de entrenamiento y validación no convergieron en ningún punto; esto puede deberse a que el conjunto de observaciones es bastante limitado y que adicionalmente no se conoce la profundidad de la que fueron extraídas las muestras de Clorof_A, dado que si las profundidades de muestreo varían, no es confiable relacionar las observaciones con valores de reflectancia puesto que la radiación electromagnética es absorbida a medida que la profundidad incrementa.



5 Conclusiones

El embalse Valle de Bravo es de vital importancia para los municipios aledaños y para la Zona Metropolitana del Valle de México, ya que, proporciona más de una tercera parte del agua de la que dispone el sistema Cutzamala; en este trabajo se ejemplifican algunas de las problemáticas ambientales más importantes de dicho cuerpo de agua, por ejemplo, los altos niveles de eutrofización (producto de la actividad humana), los cuales están directamente relacionados al deterioro del recurso hídrico y del aprovechamiento del mismo.

A partir de la recopilación de muestreos asociados a imágenes satelitales fue posible desarrollar dos modelos de redes neuronales que permiten la estimación de parámetros ópticos de calidad del agua.

Los modelos desarrollados tienen la capacidad de predecir variables como la Profundidad del Disco de Secchi (PDS) y el índice de eutrofización (TSI), siendo este último un parámetro que ayuda a clasificar cuerpos de agua lénticos con base a su capacidad biológica.

Tanto el modelo de PDS como el de TSI obtuvieron valores de ajuste superiores al 60%, resultando el de TSI como el de mejor desempeño, mostrando una tasa baja en cuanto a ocurrencia de errores y predicciones satisfactorias.

Tomando en cuenta lo anterior, se concluye que los resultados obtenidos cumplen con el objetivo de la investigación, puesto que, la metodología desarrollada resultó adecuada para ser utilizada en cuerpos de agua lénticos con características climatológicas similares a las de la presa Miguel Alemán.



Anexos

Tabla: Valores utilizados para el entrenamiento de las redes neuronales

Num	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2	Temp (°C)	Secchi (m)	SST (mg/L)	TSI	Clorof_A (mg/m3)
1	8427	8819	7841	8123	7551	7505	22.42	1.97	1.00	50.22	N/A
2	8339	8900	7844	8132	7550	7590	22.26	2.03	0.00	49.79	N/A
3	8448	8893	8113	8309	7716	7590	22.03	1.57	24.00	53.49	N/A
4	8309	8822	7705	8125	7469	7335	22.27	1.86	1.00	51.05	N/A
5	8802	8766	7710	7950	7388	7506	22.44	1.88	1.00	50.89	N/A
6	8071	8633	7576	7950	7306	7506	22.40	1.74	15.00	52.01	N/A
7	8509	8767	7851	8198	7555	7592	22.34	1.96	15.00	50.29	N/A
8	8466	8912	7862	8090	7559	7593	22.30	1.82	9.00	51.36	N/A
9	8458	8840	7857	8144	7558	7507	22.43	1.83	9.00	51.28	N/A
10	8508	8767	7852	8076	7638	7337	22.39	1.71	27.00	52.26	N/A
11	8324	8638	7580	7955	7390	7252	22.42	1.78	12.00	51.68	N/A
12	8198	8701	7578	7892	7390	7337	22.21	1.65	17.00	52.78	N/A
13	8188	8694	7708	7885	7305	7336	22.22	1.43	15.00	54.84	N/A
14	8560	9087	8118	8494	7718	7676	22.51	1.49	16.00	54.25	N/A
15	8397	8906	7858	7963	7475	7338	22.38	1.61	23.00	53.13	N/A
16	8474	9048	8002	8337	7726	7679	22.52	1.49	24.00	54.25	N/A
17	8534	8851	8000	8396	7726	7594	22.38	1.80	8.00	51.52	N/A
18	8366	8928	8009	8105	7646	7595	22.44	1.83	16.00	51.28	N/A
19	8421	8832	7715	8076	7555	7506	22.37	1.79	17.00	51.60	N/A
20	8372	8868	8012	8230	7483	7426	22.21	1.88	19.00	50.89	N/A
21	8248	8672	7743	8049	7318	7342	22.26	1.58	18.00	53.40	N/A
22	8264	8813	7751	7879	7486	7343	22.12	1.70	13.00	52.34	N/A
23	8203	8747	7750	7998	7485	7258	22.22	1.81	21.00	51.44	N/A
24	8323	8811	7749	8057	7485	7088	22.38	1.48	14.00	54.34	N/A
25	8558	8999	8014	8232	7730	7595	22.28	1.73	13.00	52.09	N/A
26	8322	8810	7883	8117	7485	7596	22.21	1.96	38.00	50.29	N/A
27	8561	8936	8015	8114	7649	7596	22.29	1.80	10.00	51.52	N/A
28	8625	9068	8153	8357	7814	7766	22.50	1.83	11.00	51.28	N/A
29	8323	8874	8017	8117	7649	7596	22.57	1.67	13.00	52.60	N/A
30	8441	8938	8016	8355	7649	7596	22.62	1.61	13.00	53.13	N/A
31	8499	9064	8014	8293	7731	7596	22.58	1.58	8.00	53.40	N/A
32	8425	8670	7740	7985	7482	7510	22.67	1.38	13.00	55.35	N/A
33	8494	9061	8012	8350	7647	7595	22.57	1.56	12.00	53.58	N/A
34	8173	8662	7735	7978	7315	7509	22.63	1.38	31.00	55.35	N/A
35	8547	9120	8143	8404	7728	7765	22.51	1.43	17.00	54.84	N/A
36	8307	8756	7843	8125	7387	7250	22.30	1.60	14.00	53.22	N/A
37	8242	8885	7704	8063	7551	7250	22.35	1.94	7.00	50.44	N/A
38	8357	9251	9295	8390	7736	7464	19.22	2.10	14.00	49.30	21.31
39	9824	10207	9804	9840	9075	8862	23.09	3.00	10.00	44.15	78.00



Num	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2	Temp (°C)	Secchi (m)	SST (mg/L)	TSI	Clorof_A (mg/m3)
40	8211	8927	7730	8020	7252	7362	19.66	2.00	14.00	50.00	2.92
41	10342	12328	10897	10866	9574	9168	24.40	0.20	54.00	83.22	19.65
42	10297	12174	10283	10745	9570	9256	23.50	0.20	NULL	83.22	11.28
43	10242	12183	10564	10744	9569	9257	23.50	0.20	16.87	83.22	8.82
44	65535	65535	33641	65535	65535	31633	15.80	0.80	NULL	63.22	1.27
45	10124	11576	10542	10584	9564	9000	23.50	0.20	13.50	83.22	10.05
46	9243	9535	11542	9529	11923	10394	17.40	0.41	12.00	72.86	27.55
47	8374	8372	7986	8187	7632	7587	18.10	0.40	14.00	73.22	15.49
48	8474	8276	8009	8097	7561	7425	17.90	0.30	14.00	77.37	31.83
49	8283	8462	8264	8147	7558	7506	18.00	0.40	12.00	73.22	41.16
50	8475	8606	8142	8217	7642	7425	17.60	0.30	16.00	77.37	23.34
51	8818	9102	9708	8555	8333	7983	31.20	2.00	NULL	50.00	3.13
52	10208	10833	8998	10582	7473	7429	21.40	0.28	70.00	78.37	0.00
53	10294	11293	10527	11843	8394	8234	24.30	0.30	256.67	77.37	0.00
54	10068	10665	9010	10869	7721	7506	22.90	0.20	10.50	83.22	0.47
55	9443	10063	8230	9857	7406	7438	21.90	0.34	20.00	75.56	14.94
56	11047	11693	10295	11597	8637	8515	20.50	0.89	156.67	61.76	2.10
57	10364	11232	10268	11846	8078	7987	24.10	0.30	76.67	77.37	0.00
58	9490	10092	8256	9810	7324	7347	21.00	0.40	29.55	73.22	18.17
59	10597	11563	10532	11967	8397	8318	23.10	0.40	36.67	73.22	0.00
60	9682	10738	9914	10006	8378	8039	23.90	0.50	25.00	70.00	16.71
61	8160	8342	7628	8019	7308	7556	25.00	0.42	15.61	72.52	8.44
62	10230	10903	8310	10260	7561	7315	20.70	0.20	20.00	83.22	0.50
63	9694	10687	8060	9712	7464	7336	24.60	1.00	16.00	60.00	0.52
64	10106	10673	8628	10004	7654	7727	20.90	0.35	13.00	75.15	1.42
65	9141	10193	7985	9371	7212	7240	26.00	0.47	26.73	70.89	7.28
66	10078	10909	8320	10346	7462	7528	19.20	0.30	30.00	77.37	NULL
67	9636	10749	7933	9769	7464	7257	25.50	0.40	18.00	73.22	1.21
68	8921	9419	8217	9027	7584	7536	18.80	0.50	16.00	70.00	NULL
69	9272	10437	8140	9434	7308	7237	25.00	0.47	17.53	70.89	13.26
70	9923	10687	8026	9988	7577	7535	20.30	0.30	80.00	77.37	NULL
71	10358	11145	8577	10483	7593	7438	19.10	0.40	20.00	73.22	NULL
72	10769	11943	9572	11265	8849	8523	25.60	0.30	36.00	77.37	0.77
73	10158	11976	9854	11666	9340	9179	22.90	0.60	54.00	67.37	11.61
74	8401	10206	8099	9993	7349	7331	23.00	0.40	64.00	73.22	4.33
75	8465	10129	8102	9883	7512	7455	22.90	0.70	30.00	65.15	14.70
76	7883	9096	7742	8923	7410	7287	23.00	0.40	30.00	73.22	3.03
77	7806	8997	7862	8502	7811	7753	16.50	0.41	60.00	72.86	26.06
78	7641	8752	7588	8217	7527	7504	16.40	0.97	32.00	60.44	27.58
79	7540	8674	7488	8087	7463	7436	16.20	0.33	56.00	75.99	18.20
80	7242	8016	7416	7707	7458	7491	15.10	1.53	36.00	53.86	17.48
81	9517	10917	15879	11133	14584	12440	15.20	0.30	NULL	77.37	5.53



Num	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2	Temp (°C)	Secchi (m)	SST (mg/L)	TSI	Clorof_A (mg/m3)
82	8708	9435	8300	8866	7822	7746	23.10	0.30	14.00	77.37	72.26
83	8256	9024	8075	8524	7742	7687	22.10	0.45	NULL	71.52	53.47
84	8451	9075	8271	8661	7901	7820	22.90	0.40	24.00	73.22	34.10
85	8677	9273	8385	8798	7913	7809	21.30	0.30	16.00	77.37	23.34
86	7370	7787	7560	7397	7438	7391	30.60	1.30	NULL	56.21	2.82
87	7936	8369	7964	8013	7618	7485	31.40	1.00	NULL	60.00	2.37
88	7388	7774	7537	7345	7441	7402	31.00	2.00	NULL	50.00	5.42
89	10011	12607	9160	13933	7891	7685	15.00	0.18	NULL	84.74	1.52
90	9713	10655	9344	10868	7780	7628	23.40	0.25	107.50	80.00	46.35
91	9799	10743	9379	11028	7573	7472	24.30	0.30	256.67	77.37	0.00
92	9420	10624	8425	10863	7659	7576	22.90	0.20	10.50	83.22	0.47
93	8515	9946	7636	9515	7384	7405	21.90	0.34	20.00	75.56	14.94
94	8886	10425	8819	10817	7578	7573	24.30	0.30	275.00	77.37	9.00
95	9412	11175	10232	12023	7855	7867	22.80	0.20	160.00	83.22	36.00
96	9181	10571	8697	10834	7476	7444	24.10	0.30	76.67	77.37	0.00
97	8882	10369	8543	10714	7823	7753	22.60	0.20	11.50	83.22	0.00
98	8805	10156	7754	9760	7448	7459	22.60	0.40	29.55	73.22	18.17
99	8473	10327	8858	10789	7486	7562	23.60	0.30	72.50	77.37	0.00
100	9266	10695	8691	10935	7957	7888	23.70	0.20	11.50	83.22	0.00
101	8681	9989	7611	9634	7391	7421	21.40	0.32	24.44	76.44	7.11
102	11051	11968	9821	11485	9179	8895	27.80	0.35	13.00	75.15	1.14
103	8423	9999	6997	8810	7222	7346	25.80	0.50	82.50	70.00	12.07
104	9717	11637	9775	10918	8894	8630	24.30	0.40	19.50	73.22	2.37
105	10254	11496	9981	11124	8855	8530	25.80	0.30	37.14	77.37	34.37
106	11048	11976	9621	11406	9114	8853	25.40	0.45	22.50	71.52	NULL
107	8313	9862	7152	8769	7359	7405	25.70	0.50	30.00	70.00	7.93
108	11127	12117	9654	11517	9180	8954	24.80	0.37	11.00	74.34	1.38
109	8507	9932	7226	8780	7232	7306	24.50	0.50	58.00	70.00	10.24
110	8229	10041	7494	9276	7939	7976	22.00	0.37	13.00	74.34	1.25
111	8401	10205	7373	9094	7890	7952	25.00	0.50	16.50	70.00	1.77
112	8970	10674	8073	9885	8051	8025	28.50	0.50	22.00	70.00	9.70
113	10941	12023	9851	11450	9429	9117	24.60	0.50	32.50	70.00	NULL
114	9267	10258	7879	9871	7437	7385	25.00	0.45	12.50	71.52	3.32
115	8052	9669	7124	8881	7204	7278	22.10	0.30	NULL	77.37	NULL
116	11094	12057	9860	11512	9516	9205	25.50	0.24	14.50	80.59	0.50
117	9307	10301	7938	9796	7487	7436	25.40	0.60	13.50	67.37	5.15
118	8238	9685	7064	9032	7203	7267	21.60	0.30	17.00	77.37	0.50
119	9568	11405	12090	10230	8889	8219	26.40	0.50	450.00	70.00	25.87
120	11250	12181	10165	11732	9734	9363	26.90	0.41	88.00	72.86	3.12
121	9712	10505	8019	9984	7505	7441	24.20	0.40	20.00	73.22	11.95
122	8123	9767	7071	8947	7199	7278	21.60	0.30	18.50	77.37	0.50
123	8897	10636	8162	9744	8078	8069	25.50	0.30	168.57	77.37	20.07



Num	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2	Temp (°C)	Secchi (m)	SST (mg/L)	TSI	Clorof_A (mg/m3)
124	11212	12156	10150	11835	9715	9410	23.70	0.51	35.33	69.71	1.82
125	9128	10226	7795	9734	7485	7457	22.30	0.50	10.00	70.00	1.90
126	8199	9665	7098	9068	7194	7270	20.60	0.32	50.77	76.44	0.50
127	10178	11924	11310	11418	9625	9196	24.40	0.40	29.00	73.22	1.19
128	10734	11644	9461	11214	8903	8666	25.00	0.38	17.00	73.96	4.28
129	10678	11624	9289	11093	8761	8552	25.60	0.37	16.50	74.34	1.91
130	8343	9858	6927	8807	7151	7284	25.00	0.30	153.33	77.37	10.18
131	10442	11940	10631	11373	9226	8877	25.30	0.40	98.57	73.22	2.72
132	11062	11954	9668	11451	9098	8814	25.30	0.35	26.00	75.15	0.97
133	8281	10170	7778	9287	7907	7940	24.70	0.30	33.75	77.37	21.53
134	11322	11290	10293	11935	9836	9503	23.30	0.47	67.14	70.89	4.38
135	8194	9551	7069	9113	7239	7322	21.80	0.50	15.50	70.00	0.95
136	8296	9689	7145	9235	7224	7304	20.60	0.40	33.13	73.22	0.50
137	10065	11182	9716	10338	9320	9074	21.92	1.00	N/A	60.00	N/A
138	10304	11428	9964	10730	9705	9233	23.79	1.00	N/A	60.00	N/A
139	10353	11484	10086	10727	9627	9312	23.02	1.10	N/A	58.62	N/A
140	8918	9514	11467	8990	9472	8918	22.42	1.07	N/A	59.02	N/A
141	10560	11597	10334	10833	9780	9314	22.58	1.21	N/A	57.25	N/A
142	10209	11352	9701	10584	9394	9155	22.13	1.10	N/A	58.62	N/A
143	10209	11231	9577	10436	9394	9156	22.28	1.28	N/A	56.44	N/A
144	10272	11234	9581	10384	9241	9076	21.91	1.05	N/A	59.30	N/A
145	9996	11117	9585	10331	9242	8917	21.88	1.11	N/A	58.49	N/A
146	10227	11239	9713	10278	9243	8996	22.09	1.06	N/A	59.16	N/A
147	10396	11358	9839	10503	9397	9312	22.37	1.03	N/A	59.57	N/A
148	9842	10884	9341	9948	8859	8838	22.27	1.14	N/A	58.11	N/A
149	9918	10953	9477	10072	9169	8759	22.68	1.09	N/A	58.76	N/A
150	9968	11010	9350	10123	9169	8837	22.35	1.06	N/A	59.16	N/A
151	10135	11069	9599	10235	9246	8839	22.47	1.00	N/A	60.00	N/A
152	10144	11074	9729	10350	9247	8838	22.53	0.83	N/A	62.69	N/A
153	10083	10952	9352	10015	9016	8680	22.53	0.91	N/A	61.36	N/A
154	9915	10892	9351	9902	8862	8601	22.44	1.07	N/A	59.02	N/A
155	9532	10600	8982	9630	8710	8365	22.18	0.72	N/A	64.74	N/A
156	9591	10719	9232	9797	8557	8523	21.93	1.10	N/A	58.62	N/A
157	9699	10481	8984	9631	8557	8367	21.49	1.15	N/A	57.98	N/A
158	9480	10424	8861	9522	8482	8288	21.53	1.00	N/A	60.00	N/A
159	9534	10541	8987	9633	8635	8524	21.78	0.95	N/A	60.74	N/A
160	9753	10659	9111	9633	8789	8445	21.82	1.00	N/A	60.00	N/A
161	9872	10958	9487	10134	9173	8917	21.68	0.92	N/A	61.20	N/A
162	9825	10668	9241	9918	8790	8838	22.37	1.00	N/A	60.00	N/A
163	9885	10728	9365	9973	9021	8916	22.79	1.00	N/A	60.00	N/A
164	9885	10727	9365	9862	8943	8603	22.55	1.03	N/A	59.57	N/A
165	9775	10610	9242	9918	8944	8601	22.19	0.96	N/A	60.59	N/A



Num	Azul	Verde	NIR	Roja	SWIR 1	SWIR 2	Temp (°C)	Secchi (m)	SST (mg/L)	TSI	Clorof_A (mg/m3)
166	9447	10258	8996	9534	8638	8288	23.31	0.89	N/A	61.68	N/A
167	9445	10198	8995	9643	8561	8524	23.24	0.88	N/A	61.84	N/A
168	9555	10375	8994	9587	8561	8601	22.76	0.97	N/A	60.44	N/A
169	9443	10315	8870	9477	8560	8288	22.93	0.89	N/A	61.68	N/A
170	9716	10431	8992	9585	8560	8288	22.56	0.80	N/A	63.22	N/A
171	9826	10607	9240	9860	8866	8680	22.35	1.00	N/A	60.00	N/A
172	9956	11064	9592	10284	9321	9074	22.64	1.00	N/A	60.00	N/A
173	10197	11183	9842	10283	9321	9074	22.59	1.00	N/A	60.00	N/A
174	10292	11362	10091	10506	9552	9311	22.62	0.86	N/A	62.18	N/A
175	9098	9446	9003	8974	8051	7737	22.50	0.50	NULL	70.00	8.94
176	8396	8245	8171	8184	7657	7334	18.20	0.47	NULL	70.89	4.88
177	8137	8141	8074	7938	7584	7526	16.10	0.90	12.00	61.52	NULL
178	10885	12821	9203	13433	7442	7176	18.50	0.18	13.00	84.74	0.50
179	10880	12745	9195	13365	7528	7174	18.50	0.18	13.00	84.74	0.50
180	8564	8809	8461	8710	8315	8226	19.00	0.50	16.00	70.00	NULL
181	8583	9058	8096	8572	7549	7466	17.50	0.59	19.00	67.61	9.95
182	10757	12537	9203	13107	7442	7455	17.30	0.18	21.00	84.74	0.40
183	10752	12531	9194	13169	7439	7360	17.30	0.18	21.00	84.74	0.40
184	9207	10163	8416	9576	7348	7321	19.80	0.54	15.00	68.89	NULL
185	9161	10129	8389	9549	7337	7316	19.80	0.54	15.00	68.89	NULL
186	8683	9057	8007	8481	7559	7371	11.50	0.82	NULL	62.86	3.12
187	8463	8754	8468	8601	8317	8307	19.20	0.50	15.00	70.00	5.32
188	8452	8740	8459	8592	8314	8221	19.20	0.50	15.00	70.00	5.32
189	8723	9058	8096	8642	7549	7367	17.00	0.50	14.00	70.00	6.49
190	8475	9445	8224	9173	7521	7425	16.50	0.35	12.00	75.15	NULL
191	8220	8979	18827	8629	12365	9881	20.50	0.50	11.00	70.00	4.00
192	7854	8134	7916	7944	7630	7521	18.20	0.47	NULL	70.89	4.88
193	8279	8734	7880	8387	7485	7412	18.90	0.40	24.00	73.22	24.34
194	7711	7854	7514	7597	7470	7456	20.10	0.46	12.00	71.20	4.61
195	13302	15275	12273	15852	11033	10544	18.20	0.23	42.00	81.20	4.33
196	9053	14045	14202	14627	13065	12592	13.40	0.30	68.00	77.37	NULL
197	9145	10806	11791	10476	11386	11308	19.00	0.50	16.00	70.00	NULL
198	12979	14950	12590	14661	11281	10743	18.07	0.23	24.00	81.20	4.81
199	7872	8739	7616	8388	7468	7429	17.00	0.50	14.00	70.00	6.49
200	7744	8589	7275	8077	7379	7406	17.00	0.44	17.00	71.84	49.92

Fuente: Elaboración propia



Bibliografía

3. *Brief introduction to remote sensing – semi-automatic classification plugin*

5.3.6.1 *documentation*. (s/f). Readthedocs.Io. Recuperado el 24 de agosto de 2023, de https://semiautomaticclassificationmanual-v5.readthedocs.io/en/latest/remote_sensing.html

Agropedia. (s/f). Agrotendencia.tv. Recuperado el 24 de agosto de 2023, de <https://agrotendencia.tv/agropedia/>

Aguilar, P. O. (s/f). *Descripción, función y uso de los sistemas de percepción remota*.

https://cursos.clavijero.edu.mx/cursos/134_ehmrn/modulo3/contenido/tema3.1.0.html

Aguirre Gómez, R. (2015). Análisis espectral del Lago de Guadalupe, mediante imágenes de satélite y datos in situ. *Investigaciones Geograficas*, 0(86), 15–24. <https://doi.org/10.14350/rig.42338>

Ahmed, W., Mohammed, S., El-Shazly, A., & Morsy, S. (2023). Tigris River water surface quality monitoring using remote sensing data and GIS techniques. *Egyptian Journal of Remote Sensing and Space Sciences*, 26(3), 816–825. <https://doi.org/10.1016/j.ejrs.2023.09.001>

Alfa Geomatics. (s/f). Alfa Geomatics. Recuperado el 24 de agosto de 2023, de <https://alfageomatics.com/>



Ariza, A. (2013). *Descripción y Corrección de Productos Landsat 8*.

<https://www.un-spider.org/sites/default/files/LDCM-L8.R1.pdf>

Carlson, R. E. (1977). A trophic state index for lakes¹: Trophic state index. *Limnology and oceanography*, 22(2), 361–369.

<https://doi.org/10.4319/lo.1977.22.2.0361>

Centro Nacional de Prevención de Desastres. (s/f). *Tecnología espacial y percepción remota en la prevención de desastres*. gob.mx. Recuperado el 23 de septiembre de 2023, de

<https://www.gob.mx/cenapred/articulos/tecnologia-espacial-y-percepcion-remota-en-la-prevencion-de-desastres>

Chawira, M., Dube, T., & Gumindoga, W. (2013). Remote sensing based water quality monitoring in Chivero and Manyame lakes of Zimbabwe. *Physics and Chemistry of the Earth* (2002), 66, 38–44.

<https://doi.org/10.1016/j.pce.2013.09.003>

Chu, H.-J., & He, Y.-C. (2023). Remote sensing water quality inversion using sparse representation: Chlorophyll-a retrieval from Sentinel-2 MSI data. *Remote Sensing Applications Society and Environment*, 31(101006), 101006.

<https://doi.org/10.1016/j.rsase.2023.101006>

Comisión Nacional del Agua. (s/f). *Calidad del agua en México*. gob.mx.

Recuperado el 8 de mayo de 2023, de

<https://www.gob.mx/conagua/articulos/calidad-del-agua>



CONAGUA. (2005). Sistema Cutzamala. Agua para millones de mexicanos. *Sistema Cutzamala*, 1, 48.

<https://www.conagua.gob.mx/conagua07/publicaciones/publicaciones/sistema-cutzamala.pdf>

Diagnosing model performance with learning curves. (s/f). Github.io. Recuperado el 8 de junio de 2023, de <https://rstudio-conf-2020.github.io/dl-keras-tf/notebooks/learning-curve-diagnostics.nb.html>

Díaz González, F. A., Quintero Torres, S. V., Triana Correa, J. S., & Morón Hernández, D. C. (2014). *APROXIMACIÓN A LOS SISTEMAS DE PERCEPCIÓN REMOTA EN SATÉLITES PEQUEÑOS* (Primera edición). Universidad Sergio Arboleda.

Diseño Experimental. (s/f). Edu.co. Recuperado el 5 de junio de 2023, de http://red.unal.edu.co/cursos/ciencias/2007315/html/un6/cont_02_63.html

Embalse Villa Victoria. (s/f). Remexcu.org. Recuperado el 1 de agosto de 2023, de <https://remexcu.org/index.php/grupos/fichas-informativas-de-lagos/mexico/embalse-villa-victoria>

Flores Márquez, M. P. (2005). *Caracterización Limnológica de la Presa Atlangatepec, Tlaxcala, México*. Universidad Nacional Autónoma de México.



Galvañ Sala, D. A. (2021). *Comparativa de técnicas para la prevención del sobreajuste en redes neuronales*. Escuela Politécnica Superior .

Plan estratégico para la recuperación ambiental de la Cuenca Amanalco-Valle de Bravo: Actualización, Instituto Mexicano de Tecnología del Agua (IMTA), noviembre de 2012, 2 Fondo para la Comunicación y la Educación Ambiental, A.C. (FCEA) 1, <https://agua.org.mx/biblioteca/plan-estrategico-para-la-recuperacion-ambiental-de-la-cuenca-amanalco-valle-de-bravo-actualizacion/>

Instituto Nacional de Estadística y Geografía (INEGI). (s/f). *Aspectos Técnicos De Las Imágenes LANDSAT*.
<https://www.inegi.org.mx/temas/imagenes/imgLANDSAT/#Documentacion>

Jalisco. (s/f). *Secretaría de Medio Ambiente y Desarrollo Territorial*. Gob.mx.
Recuperado el 1 de agosto de 2023, de <https://semadet.jalisco.gob.mx/1973-lago-de-chapala>

Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (2007). Comparación del Desempeño de Funciones de Activación en Redes Feedforward para aproximar Funciones de Datos con y sin Ruido. *Avances en Sistemas e Informática*, 4(II), 80–88.

Manifiestación de Impacto Ambiental L. T. Lázaro Cárdenas Entrq La Villita-SERSIINSA. (s/f). Gob.mx. Recuperado el 1 de agosto de 2023, de



<http://sinat.semarnat.gob.mx/dgiraDocs/documentos/gro/estudios/2004/12GE2004E0009.pdf>

Matich, D. J. (Marzo de 2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. En M. S. B. Carlos Alberto Ruiz (Ed.), *Informática Aplicada a la Ingeniería de Procesos – Orientación I* (pp. 8–18). Universidad Tecnológica Nacional.

Nasir, N., Kansal, A., Alshaltone, O., Barneih, F., Shanableh, A., Al-Shabi, M., & Al Shammaa, A. (2023). Deep learning detection of types of water-bodies using optical variables and ensembling. *Intelligent Systems with Applications*, 18(200222), 200222.
<https://doi.org/10.1016/j.iswa.2023.200222>

Navarro Moreno, I. M. (2002). *Microcistinas presencia, determinación y estudios toxicológicos*. Universidad de Sevilla .

Niazkar, M., Menapace, A., Brentan, B., Piraei, R., Jimenez, D., Dhawan, P., & Righetti, M. (2024). Applications of XGBoost in water resources engineering: A systematic literature review (Dec 2018–May 2023). *Environmental Modelling & Software: With Environment Data News*, 174(105971), 105971. <https://doi.org/10.1016/j.envsoft.2024.105971>

Osorio Hernández, M. A. (2011). *Evaluación de la Calidad Del Agua en el Vaso de la Presa Valle De Bravo a Partir De Campañas de Muestreo Realizadas en 2010 y 2011*. UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO.



Percepción Remota. (s/f). Gob.mx. Recuperado el 8 de mayo de 2023, de
<https://2006-2012.semar.gob.mx/informacion-sector/ciencia/ermexs/temas-de-interes/384-percepcion-remota.html>

Plan Municipal de Desarrollo Urbano del Municipio de Valle de Bravo, México.
(2020).

<https://legislacion.edomex.gob.mx/sites/legislacion.edomex.gob.mx/files/files/pdf/gct/2020/jun122.pdf>

Revista CyT (Vol. 1, Número 2009). (2010). Instituto Mexicano del Cemento y del Concreto.

<https://www.imcyc.com/revistacyt/oct10/especial.htm#:~:text=La%20presencia%20de%20Jos%C3%A9%20Mar%C3%ADa%20Morelos,1964%20y%20julio%20de%201968>.

Ross, M. R. V., Topp, S. N., Appling, A. P., Yang, X., Kuhn, C., Butman, D., Simard, M., & Pavelsky, T. M. (2019). AquaSat: A data set to enable remote sensing of water quality for inland waters. *Water Resources Research*, 55(11), 10012–10025. <https://doi.org/10.1029/2019wr024883>

Roy, S., & Das, B. S. (2022). Estimation of euphotic zone depth in shallow inland water using inherent optical properties and multispectral remote sensing imagery. *Journal of Hydrology*, 612(128293), 128293.
<https://doi.org/10.1016/j.jhydrol.2022.128293>



RProject. (2022). *Package 'neuralnet'*. <https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>

RPubs - MAE y RMSE. (s/f). Rpubs.com. Recuperado el 5 de junio de 2023, de https://rpubs.com/stefenso7/MAE_RMSE

Santana, J. S., & Mateos Farfán, E. (2014). *El arte de programa en R: un lenguaje para la estadística* (Primera edición). Instituto Mexicano de Tecnología del Agua. https://cran.r-project.org/doc/contrib/Santana_El_arte_de_programar_en_R.pdf

Santos Téllez, R. U., Instituto Mexicano de Tecnología del Agua, Morelos, México, Medina Mendoza, R., Rodríguez Varela, J. M., Instituto Mexicano de Tecnología del Agua, Morelos, México, & Instituto Mexicano de Tecnología del Agua, Morelos, México. (2021). Vulnerabilidad del Cutzamala. *Perspectivas IMTA*, 2(18). <https://doi.org/10.24850/b-imta-perspectivas-2021-18>

Sepúlveda Hirose, R. T. (2011). *Diseño de modelos de calidad del agua mediante el uso de la percepción remota*. Universidad Nacional Autónoma de México.

Topp, S. N., Pavelsky, T. M., Stanley, E. H., Yang, X., Griffin, C. G., & Ross, M. R. V. (2021). Multi-decadal improvement in US Lake water clarity. *Environmental research letters*, 16(5), 055025. <https://doi.org/10.1088/1748-9326/abf002>



Traversoni Domínguez, L., Vélez, H., Ruiz Martínez, R., & Carreón Cordero, E.

(s/f). *Manifestación de Impacto Ambiental Presa “Manuel Ávila Camacho”, Valsequillo, Puebla.*

<http://sinat.semarnat.gob.mx/dgiraDocs/documentos/pue/estudios/2009/21PU2009HDO56.pdf>

Villegas Vega, H. (2008). *Introducción a la Percepción Remota y sus Aplicaciones Geológicas (Guías para los asistentes).*

<https://recordcenter.sgc.gov.co/B12/23008002524448/documento/pdf/2105244481102000.pdf>

Vinuesa, P. (2016). *Tema 8 - Correlación: teoría y práctica.* Unam.mx.

https://www.ccg.unam.mx/~vinuesa/R4biosciences/docs/Tema8_correlacion.html

Zhu, X., Guo, H., Huang, J. J., Tian, S., Xu, W., & Mai, Y. (2022). An ensemble machine learning model for water quality estimation in coastal area based on remote sensing imagery. *Journal of Environmental Management*, 323(116187), 116187.

<https://doi.org/10.1016/j.jenvman.2022.116187>