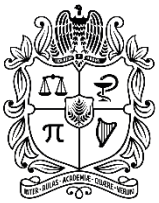

UNIVERSIDAD
NACIONAL
DE COLOMBIA

Metodología para la determinación de parámetros de calidad del agua en cuerpos lénticos haciendo uso de imágenes multiespectrales de dron y aprendizaje computacional

Diego Joaquín Rugeles Martínez

Universidad Nacional de Colombia
Ciencias Agrarias, Maestría en Geomática
Bogotá, Colombia
2025

Metodología para la determinación de parámetro de calidad del agua en cuerpos lenticos haciendo uso de imágenes multiespectrales de dron y aprendizaje computacional

Diego Joaquín Rugeles Martínez

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Geomática

Director (a):

Ph.D., Luis Joel Martínez Martínez

Línea de Investigación:

Geoinformación para el uso sostenible de los recursos naturales

Universidad Nacional de Colombia

Ciencias Agrarias, Maestría en Geomática

Bogotá, Colombia

2025

Dedicatoria:

A Dios por darme la sabiduría, conciencia y respaldo para poder ejecutar este trabajo, a mi mamá porque sus oraciones, consejos y apoyo incondicional fue posible para mi realizar mi maestría, a mi padre por su constante entrega para mi formación llevándome siempre por el camino correcto. A mi hermana por su constante amor y cariño en todas las etapas de mi vida. A mis amigos por brindarme una mano en los momentos que más los necesite y siempre creer en mí.

Agradecimientos

A la facultad de ciencias agrarias de la Universidad Nacional de Colombia por brindarme los espacios, herramientas y conocimientos necesarios para poder llevar a cabo este trabajo.

Al profesor Luis Joel Martinez por apoyarme en todas las etapas de este trabajo de grado brindándome su conocimiento y experiencia.

A Diego Torres, Michael Rojas, Yaritza Quevedo, Tatiana Rodríguez, Carolina Galindo y Angelica Quintana por ayudarme en los vuelos de UAS y muestreos de los parámetros de calidad de agua.

A todas las personas que dedicaron un espacio para apoyarme en la ejecución de este trabajo de grado.

Resumen

Metodología para la determinación de parámetro de calidad del agua en cuerpos lenticos haciendo uso de imágenes multiespectrales de dron y aprendizaje computacional

El uso de sensores remotos multiespectrales acoplados a aeronaves no tripuladas representa una alternativa ágil y económica para la estimación de parámetros de calidad del agua. Sin embargo, en zonas tropicales y en el contexto colombiano, el conocimiento sobre su modelamiento mediante algoritmos de aprendizaje automático sigue siendo limitado. Este estudio tiene como objetivo desarrollar una metodología para evaluar la calidad del agua en cuerpos lénticos utilizando imágenes multiespectrales obtenidas con UASy tres parámetros clave: turbidez, fosfatos y nitratos. Se empleó un dron DJI M300 RTK con el sensor RedEdge Micasense P para generar ortoimágenes multiespectrales sobre dos cuerpos de agua en Cundinamarca, Colombia. Además, se recolectaron 30 muestras espacializadas de los parámetros mencionados. Se calcularon índices espectrales de agua y vegetación, y mediante regresión por mínimos cuadrados parciales (PLS), se determinó la importancia de cada variable en la predicción. Posteriormente, se desarrollaron y compararon tres algoritmos de aprendizaje automático: SVR, RFR y GBR. Los resultados demostraron una asociación significativa entre la reflectancia multiespectral y los parámetros de calidad del agua, con los índices de agua y vegetación como las variables más influyentes. Entre los modelos evaluados, GBR mostró el mejor desempeño, con un ajuste óptimo en el entrenamiento y el menor RMSE en la validación. Estos hallazgos destacan el potencial del aprendizaje automático para la estimación espacial de la calidad del agua, lo que resulta clave para la gestión de los recursos hídricos y la conservación de los servicios ecosistémicos de los cuerpos de agua lénticos.

Palabras clave: Aprendizaje automático, Calidad del agua, UAS, Índices espectrales, Sensores multiespectrales, Teledetección.

Abstract

Methodology for Determining Water Quality Parameters in Lentic Water Bodies Using Drone Multispectral Images and Machine Learning

The use of unmanned aerial vehicles equipped with multispectral remote sensors provides a fast and cost-effective alternative for estimating water quality parameters. However, in tropical regions and within the Colombian context, knowledge about their modeling through machine learning algorithms remains limited. This study aims to develop a methodology for assessing water quality in lentic water bodies using multispectral drone imagery and three key parameters: turbidity, phosphates, and nitrates. A DJI M300 RTK drone equipped with the RedEdge Micasense P sensor was used to generate multispectral orthomosaics over two lentic water bodies in Cundinamarca, Colombia. Additionally, 30 spatially distributed samples of the mentioned parameters were collected. Water and vegetation spectral indices were calculated, and the importance of each variable in prediction was determined using Partial Least Squares (PLS) regression. Subsequently, three machine learning algorithms—SVR, RFR, and GBR—were developed and compared. The results demonstrated a significant association between multispectral reflectance and water quality parameters, with water and vegetation indices being the most influential variables. Among the evaluated models, GBR showed the best performance, with optimal training fit and the lowest RMSE in validation. These findings highlight the potential of machine learning for spatial estimation of water quality, which is essential for water resource management and the conservation of the ecosystem services provided by lentic water bodies.

Keywords: Drone, Machine learning, Multispectral sensors, Remote sensing, Spectral indices, Water quality.

Contenido

Pág.

2. Objetivos 5
2.1 Objetivo General 5
2.2 Objetivos Específicos 5

3. Marco de referencia 7
3.1 Propiedades ópticas del agua 7
3.2 Parámetros fisicoquímicos influyentes en la calidad del agua 11
3.3 Imágenes multiespectrales de UAS 14
3.4 Índices espectrales y su relación con los parámetros de calidad de agua 14
3.5 Modelamiento de parámetros de calidad de agua 16

4. Materiales y métodos 19
4.1 Flujo de trabajo 19
4.2 Área de estudio 20
4.3 Variables de estudio 22
4.4 Adquisición de datos 23
4.5 Pre – Procesamiento 29
4.6 Análisis y modelamiento 30
4.7 Validación de modelos 32

5. Resultados 33
5.1 Análisis exploratorio de datos 33
5.2 Estimación de las importancias de las variables predictoras 35
5.3 Potencial de las imágenes UAS para estimar parámetros de calidad de agua. 37
5.4 Desempeño de los algoritmos de aprendizaje computacional 42
5.4 Validación de los modelos generados 50

6. Discusión 54
6.1 Metodología para la estimación de parámetros de calidad de agua a partir de imágenes UAS y aprendizaje computacional 57

7. Conclusiones 65
a. Conclusiones 65
b. Recomendaciones 66

Lista de figuras

Pág.

Figura 3-1 Respuesta espectral del agua pura 8
Figura 3-2 Respuesta espectral del agua pura en función al grosor de la lámina de agua9
Figura 3-3 Respuesta espectral del agua en función a la temperatura 10
Figura 3-4 Cambios en las propiedades espectrales del agua a diferentes concentraciones de turbidez..... 11
Figura 3-5 Cambios en las propiedades espectrales del agua a diferentes concentraciones de turbidez en un cuerpo de agua lentico 12
Figura 3-6 Respuestas espectrales de diferentes parámetros de calidad del agua..... 13
Figura 4-1 Diagrama metodológico para la estimación de parámetros de calidad de agua 19
Figura 4-2 Laguna La Herrera 21
Figura 4-3 Laguna de Ubaque 21
Figura 4-4 Zonas de estudio. ESPG: 9377 22
Figura 4-5 Sistema UAS, Sensor y Antena Utilizado 24
Figura 4-6 Calibración del IMU y brújula UAS DJI Matrice 300 RTK 25
Figura 4-7 Muestreo de agua realizado (A,B Muestreo Laguna la Herrera), (C,D Muestreo en Laguna de Ubaqué) 27
Figura 4-8 Puntos de muestreo en las zonas de estudio (A. Laguna La Herrera, B. Laguna de Ubaque)..... 28
Figura 4-9 Kernel utilizado para el cálculo de las reflectancias medias en cada punto de muestreo 30
Figura 5-1 Distribución en las concentraciones de los parámetros de calidad de agua en las zonas de estudio (A. Turbidez, B. Nitratos, C. Fosfatos)..... 33
Figura 5-2 Tabla de correlación de Pearson entre las variables de estudio 35
Figura 5-3 Importancia de las variables predictoras para la estimación de parámetros de calidad de agua (A. Laguna La Herrera, B. Laguna de Ubaqué) 36
Figura 5-4 Ortoimagenes e índices espectrales generados de las áreas de estudio. (A. Ortoimagen Laguna La Herrera, B. Índice NDVI Laguna La Herrera, C. Índice NDWI Laguna La Herrera. D. Ortoimagen Laguna Ubaqué, E. Índice NDVI Laguna Ubaqué, F. Índice NDWI Laguna U)..... 39
Figura 5-5 Respuestas espectrales del agua en diferentes concentraciones de Turbidez (A. Laguna La Herrera, B. Laguna de Ubaque) 41

Figura 5-6 Espacialización de los parámetros de calidad de agua en la Laguna la Herrera. (A. Turbidez con SVR, Turbidez con RFR, C. Turbidez con GBR, D. Nitratos con SVR, E. Nitratos con RFR, F. Nitratos con GBR, G. Fosfatos con SVR, H. Fosfatos con RFR, I. Fosfatos con GBR) EPSG: 9377 47
Figura 5-7 Espacialización de los parámetros de calidad de agua en la Laguna Ubaque. (A. Fosfatos con SVR, Fosfatos con RFR, C. Fosfatos con GBR, D. Nitratos con SVR, E. Nitratos con RFR, F. Nitratos con GBR, G. Turbidez con SVR, H. Turbidez con RFR, I. Turbidez con GBR) EPSG: 9377 50
Figura 5-8 RMSe encontrado en las estimaciones espaciales de los parámetros de calidad de agua 51
Figura 5-9 Validación por punto de muestreo para los parámetros de calidad de agua estimados con el algoritmo GBR (A. Turbidez Laguna La Herrera, B. Nitratos Laguna La Herrera, C. Fosfatos Laguna La Herrera, D. Turbidez Laguna Ubaque, E. Nitratos Laguna Ubaque, F. Fosfatos Laguna Ubaque). 52
Figura 6-1 Variable a remplazar por el set de datos construido 61
Figura 6-2 Sección del notebook para enrutar las bandas de la ortoimagen generada y los índices espectrales 62
Figura 6-3 Sección del notebook para enturar la salida de las representaciones espaciales de los parametros de calidad de agua. 63
Figura 6-4 Diagrama metodológico para la estimación espacial de parámetros de calidad de agua con aprendizaje automático 64

Lista de tablas

Pág.

Tabla 3-1: Índices espectrales y modelos asociados para estimar concentraciones de parámetros de calidad de agua. 15
Tabla 3-2: Referenciación de modelos para estimar parámetros de calidad de agua 18
Tabla 4-1 Variables utilizadas en el estudio 23
Tabla 4-2 Especificaciones técnicas del sensor remoto Micasense RedEdge P 24
Tabla 4-3 Rangos de longitudes de onda de medición en el sensor Micasense RedEgdeP 25
Tabla 5-1 Estadísticas generales de los parámetros de calidad de agua 33
Tabla 5-2 Hiperparametros escogidos para cada parámetro de calidad de agua 43
Tabla 5-3 Métricas de rendimiento de los modelos de aprendizaje computacional 45
Tabla 6-1 Variables más importantes encontradas en el estudio con respecto a las referenciadas en la literatura 55
Tabla 6-2 Comparación de R2 obtenidos en el estudio con los encontrados en la literatura 56
Tabla 6-3 Lista de chequeo elementos para la toma de datos UAS 58
Tabla 6-4 Actividades a realizar previa captura de la información 59
Tabla 6-5 Elementos necesarios para el muestro de calidad de agua 60
Tabla 6-6 Esquema de datos para consolidar los resultados del procesamiento de la ortoimagen y los parámetros de calidad de agua 61

Lista de Símbolos y abreviaturas

Símbolos con letras griegas

Símbolo	Término	Unidad SI
ρ	Reflectancia en superficie	%

Subíndices

Subíndice	Término
nm	Nanometros
cm	Centimetros

Superíndices

Superíndice	Término
n	Exponente, potencia

Abreviaturas

Abreviatura	Término
UAS	Unnamed Aircraft System
RTK	Real Time Kinematics
NT	Nitrogeno Total
FT	Fosforo Total
NTU	Unidades Neftelometricas de Turbidez
NDVI	Indice de vegetación normalizado
NDWI	Indice de agua normalizado
NIR	Infrarrojo cercano
PLS	Minimos cuadrados parciales
RFR	Regresión por arboles aleatorios
SVR	Regresión por máquinas de soporte
GBR	Regresión por gradiente optimizado

1. Introducción

En la superficie terrestre existen diversos tipos de cuerpo acuáticos sin caudal constante o lénticos que tienen diversas dinámicas bioquímicas y ecológicas generadoras de biodiversidad abundante y de servicios ecosistémicos, como la captación de dióxido de carbono o metano (Downing et al., 2006). Estos ecosistemas contienen el 2.5% del total de agua presente en la superficie terrestre, aun así, con este bajo porcentaje son fundamentales en procesos de agricultura, manufactura, y satisfacción de necesidades básicas como el suministro de agua potable(Sibanda et al., 2021).

Los cuerpos de agua lénticos tienen ciclos biogeoquímicos como el del fósforo, nitrógeno y carbono, que favorece la proliferación de organismos como fitoplancton, algas, cianobacterias, plantas sumergidas, crustáceos y peces manteniendo un delicado equilibrio ecológico fácilmente perturbable por aumentos rápidos de temperatura, y/o vertimiento constante de material orgánico a los cuerpos de agua (Guevara et al., 2009; Wetzel, 2001).

Hoy en día por la acción del hombre, muchos cuerpos de agua lénticos son afectados por el vertimiento de aguas residuales, la escorrentía de pesticidas y defertilizantes utilizados en procesos agroindustriales aledaños a los cuerpos de agua y aumento de la temperatura por el calentamiento global. Uno de los efectos, de lo anterior, es la eutroficación (Wetzel, 2001)—por sobreacumulación de nutrientes que potencia la proliferación de microorganismos y plantas sobre la superficie del cuerpo de agua, generando condiciones anaerobias de degradación de materia orgánica y en consecuencia la aparición de compuestos tóxicos que deterioran la calidad afectando los servicios ecosistémicosy la biodiversidad presente (Wetzel, 2001) .

Si bien los procesos de eutroficación son naturales, dada la escorrentía de minerales y materia orgánica presente en el suelo, la acción del hombre en los últimos 50 años ha

generado que la gran mayoría de cuerpos de agua presentes en el mundo ya tengan algún grado de eutroficación (Khan & Abid, 2005).

En Colombia actualmente existen diversos estudios donde evidencian fenómenos de eutroficación en cuerpos de agua como la Laguna de Tota, Laguna de Fúquene, Reserva Hidroprado, entre otros, donde se encontraron altas concentraciones de material orgánico y alta presencia en la superficie del agua de fitoplancton, cianobacterias y plantas acuáticas que han generado condiciones anaerobias y decaimiento en la calidad del agua (Abella & Martínez, 2013; Guevara et al., 2009).

Para la determinación de los niveles de eutroficación en cuerpos de agua, existen metodologías convencionales que requieren muestreos in situ y análisis fisicoquímicos de indicadores como contenido de clorofila, turbidez, sólidos suspendidos totales, nitratos, fosfatos, oxígeno disuelto, carbono orgánico total, demanda química de oxígeno entre otros (Bhateria & Jain, 2016; Thornton Robert H Kennedy A Dale Magatn & Sauf, 1982), estos métodos si bien son analíticamente exactos tienen diferentes dificultadas ya que solo genera información en un solo punto sobre el cuerpo de agua teniendo así que generalizar los resultados para la extensión total del cuerpo. Sin embargo, el uso de metodologías no convencionales basada en sensores remotos está tomando fuerza para la estimación de la calidad del agua haciendo uso de imágenes satelitales, aerotransportadas o proveniente de UAS, debido a que tiene ventajas como la adquisición de datos en tiempo real, accesibilidad a zonas de difícil topografía y reducción significativa de costos al no necesitar métodos analíticos costos y de alta complejidad (De Keukelaere et al., 2023; Sibanda et al., 2021).

En el estudio presentado por Sibanda et al., 2021 se revisó la aplicación de los UAS para el monitoreo de calidad de agua donde se resalta que la información obtenida a partir de imágenes de UAS puede ser utilizada para la estimación de diversos parámetros como el contenido de clorofila asociado a la eutroficación, demanda de oxígeno, conductividad, turbidez, nitratos, fosfatos, área de cubrimiento del espejo de agua, entre otros.

En cuanto a aplicaciones de uso de sistemas UAS para la estimación de parámetro de calidad de agua como el presentado por Robert et al., 2016 donde utilizan el sensor hiperespectral MODIS para la estimación de turbidez en embalses a partir de índices espectrales, encontrado fuertes relaciones entre la reflectancia de las imágenes y parámetros de calidad de agua. También están los estudios realizado por Cui et al., 2022;

De Keukelaere et al., 2023; Niu et al., 2021 donde a partir de sensores multiespectrales e hiperespectrales acoplados a sistemas UAS estimaron concentraciones de diferentes parámetros de calidad de agua en cuerpos de agua lenticos de baja extensión realizando modelos de aprendizaje computacional basados en las relaciones de la reflectancia de las imágenes y las concentraciones encontradas en laboratorio, estableciendo el potencial de las imágenes UAS para generar estudios de calidad de agua, esto representa un avance significativo para el para poder monitorear y gestionar la calidad de agua de forma integrada considerando la totalidad de extensión en los cuerpos de agua.

Con el desarrollo constante de la geomática, se han generado diversos tipos de metodologías con el fin de extraer información útil para la estimación de parámetros de calidad de agua a partir de los insumos provenientes de sensores remotos como puede ser el modelamiento empírico , analítico o basado en aprendizaje computacional haciendo uso de sensores, RGB, multiespectrales o hiperespectrales dispuestos en plataforma satelitales, aerotransportadas e integrados a UAS, que permiten estimar con grados de incertidumbre bajas, rangos y concentraciones de parámetros de calidad de agua (Yang et al., 2022). Lo anterior fundamentado en que la reflectancia del agua cambia en función al nivel de contaminación que esté presente, teniendo mayor reflectancia a medida que el cuerpo de agua este mas contaminado, teniendo diferencias significativas entre la reflectancia saliente del agua pura y del agua con altos índices de turbidez, nitratos, fosfatos, DQO, entre otros (Buiteveld et al., 1994; Cui et al., 2022).

Según lo anteriormente mencionado, el problema de investigación de la tesis de maestría hace referencia a la falta de una metodología que integre de forma eficiente imágenes capturadas con UAS, datos de calidad de agua tomados en campo y algoritmos de aprendizaje computacional para determinar algunos parámetros de calidad del agua clave como lo son la turbidez, nitratos y fosfatos con fines de monitoreo ambiental y de salud pública en el contexto colombiano en cuerpos de agua poco afectados y con altos niveles de contaminación.

Como hipótesis de este trabajo, existe una relación entre las respuestas espectrales captadas por sensores multiespectrales y los parámetros de calidad del agua por lo tanto se puede desarrollar un método que permita estimar dichos parámetros a partir de los datos provenientes de imágenes tomadas con UAS por la asociación existente entre la reflectancia del agua y las imágenes multiespectrales.

El desarrollo de esta metodología permitirá monito de forma constante la calidad de agua de diversos cuerpos lenticos para conocer su estado actual y así poder evaluar impactos que se tengan sobre los servicios ecosistémicos que este ofrece y poder tomar medidas de forma oportunidad para mejorar la calidad de agua de estos ecosistemas.

2. Objetivos

2.1 Objetivo General

Desarrollar una metodología para determinar parámetros de calidad del agua en cuerpos lénticos haciendo uso de imágenes multiespectrales tomadas con UAS y modelamiento basado en aprendizaje computacional.

2.2 Objetivos Específicos

- Evaluar el potencial de las imágenes capturadas con UAS para la estimación de diferentes parámetros de calidad del agua.

- Comparar el desempeño de algoritmos de aprendizaje computacional para estimar las concentraciones de diferentes parámetros de calidad del agua

- Establecer la exactitud en la determinación de los parámetros de calidad del agua para la metodología propuesta.

3. Marco de referencia

3.1 Propiedades ópticas del agua

El agua es un compuesto inorgánico generado naturalmente en la biosfera gracias a los ciclos biogeoquímicos que constituyen las dinámicas de transferencia de masa necesarias para el sostenimiento de la vida en la tierra. Las propiedades espectrales del agua son de interés para campos como la teledetección que puede detectar su estado y calidad de forma espacial (Elton, 2016).

En el estudio publicado por Buiteveld et al., 1994 se realizó la revisión de las propiedades ópticas del agua pura obtenida por diferentes autores, donde se encontró un patrón de absorbancia y longitud de onda persistente en los estudios analizados.

El agua pura tiene una absorbancia baja en las longitudes de onda que van desde los 300nm hasta los 580nm, es decir que los valores de reflectancia son los más altos en estos rangos espectrales. Por otro lado, en valores de longitud de onda entre 600nm hasta 750nm, se evidencia que el agua pura tiene coeficientes de absorción más altos, es decir que la reflectancia disminuye desde 600nm hasta llegar al mínimo de 750nm (Figura 3-1).

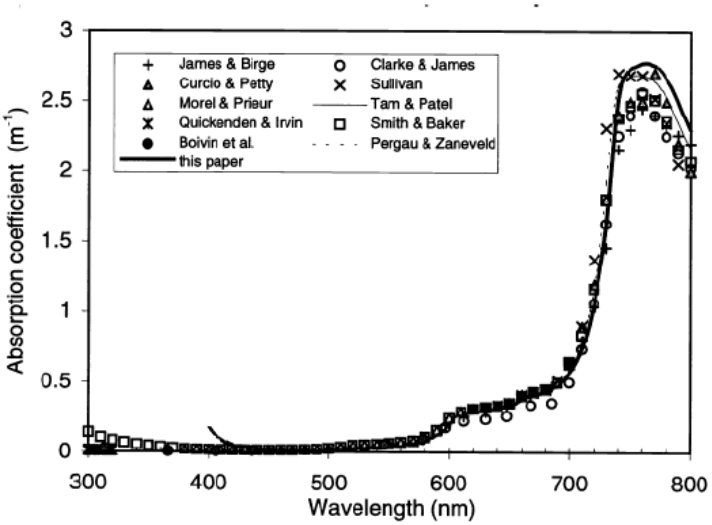

Figura 3-1 Respuesta espectral del agua pura

Fuente: (Buiteveld et al., 1994)

En el estudio presentado por Satterwhite et al., 2003 se evaluó la respuesta espectral del agua en diferentes estados, como nieve, hielo, y agua pura con diferentes láminas de agua. Allí encontró valores de reflectancia similares a los presentados por Buiteveld et al., 1994 para el agua pura. Por otro lado, se determinó que las respuestas espectrales varían en función del grosor de la lámina de agua y al estado fisicoquímico en el que se encuentre (Figura 3-2).

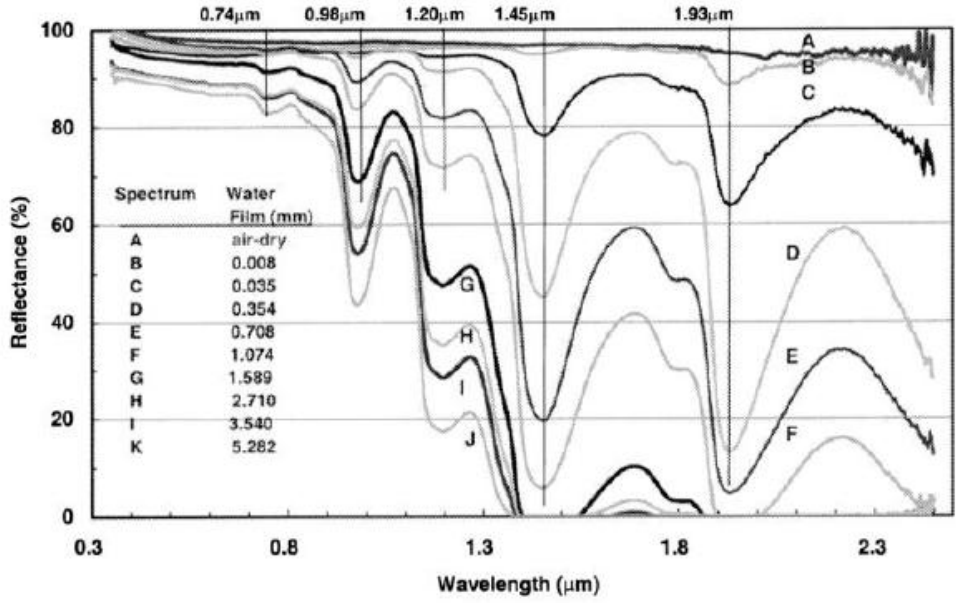

Figura 3-2 Respuesta espectral del agua pura en función al grosor de la lámina de agua

Fuente: (Satterwhite et al., 2003)

Las propiedades espectrales del agua cambian significativamente por el grosor de la lámina de agua que está siendo analizada, a medida que la lámina es más gruesa, los niveles de reflectancia son más bajos, siendo entre 10% a 15% menor cada 5mm de grosor. Lo anterior evidencia que la reflectancia es función de la profundidad del agua, siendo menor a medida que la lámina de agua se hace más gruesa.

Finalmente, las propiedades espectrales del agua pura son función de la temperatura, según lo mostrado por Buiteveld et al., 1994 donde encontró diferencias cuando la temperatura del agua analizada cambio (Figura 3-3).

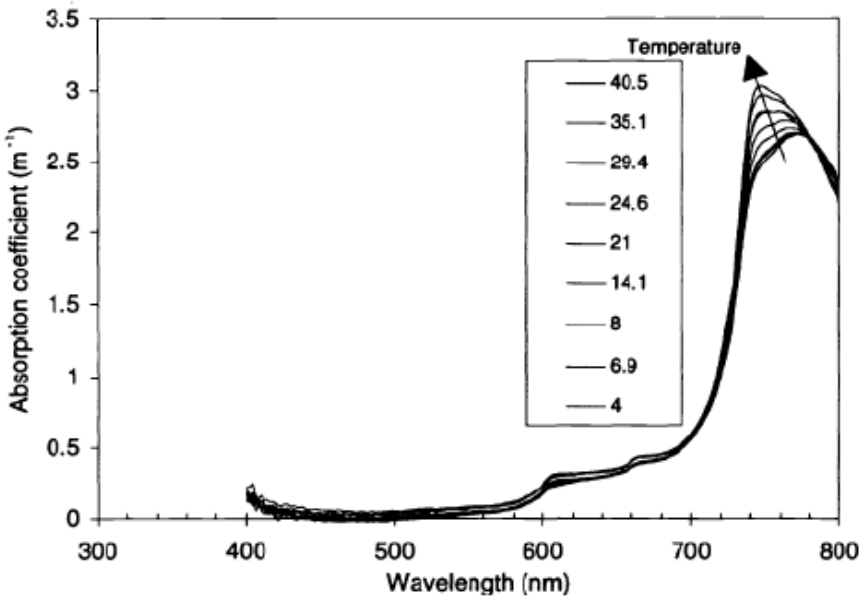

Figura 3-3 Respuesta espectral del agua en función a la temperatura

Fuente: (Satterwhite et al., 2003)

A mayor temperatura del agua, la absorción en las longitudes de onda comprendidas dentro del rango de 720nm – 780nm varia significativamente, sin embargo, para las demás longitudes de onda, la diferencia es poco apreciable.

Es importante reconocer las propiedades espectrales del agua en su estado puro y/o limpio con el fin de evidenciar las longitudes de onda donde más reflectancia existe y por ende saber discernir entre los tipos de sensores necesarios para realizar un estudio de calidad de agua, sin embargo, en los cuerpos de agua lenticos, es muy poco frecuente encontrar agua limpia, dadas las dinámicas antropogénicas que cambias las propiedades espectrales de agua y generan fenómenos de eutroficación.

3.2 Parámetros fisicoquímicos influyentes en la calidad del agua

La medición de turbidez y de la concentración nitratos y fosfatos es fundamental para la estimación de la calidad del agua en cuerpos lénticos. La turbidez indica la cantidad de partículas suspendidas en el agua, refleja el grado de sedimentación y la posible presencia de algas, que pueden ser indicativas de exceso de nutrientes (Conley et al., 2009). Los nitratos y fosfatos son nutrientes clave que, en concentraciones elevadas, impulsan el crecimiento excesivo de algas y plantas acuáticas. Este crecimiento desmedido puede llevar a la disminución del oxígeno en el agua y afectar negativamente la salud de los ecosistemas acuáticos generando condiciones anaerobias que propician la generación de compuestos tóxicos. Por lo tanto, monitorear estos parámetros proporciona información crucial sobre la calidad del agua y ayuda en la identificación de problemas asociados con eutrofización, facilitando la implementación de estrategias para la protección y restauración de estos cuerpos de agua.(Conley et al., 2009; Gao et al., 2015a)

En el estudio publicado por Cui et al., 2022 se determinaron los cambios espectrales que tiene el agua a diferentes concentraciones de turbidez (Figura 3-4).

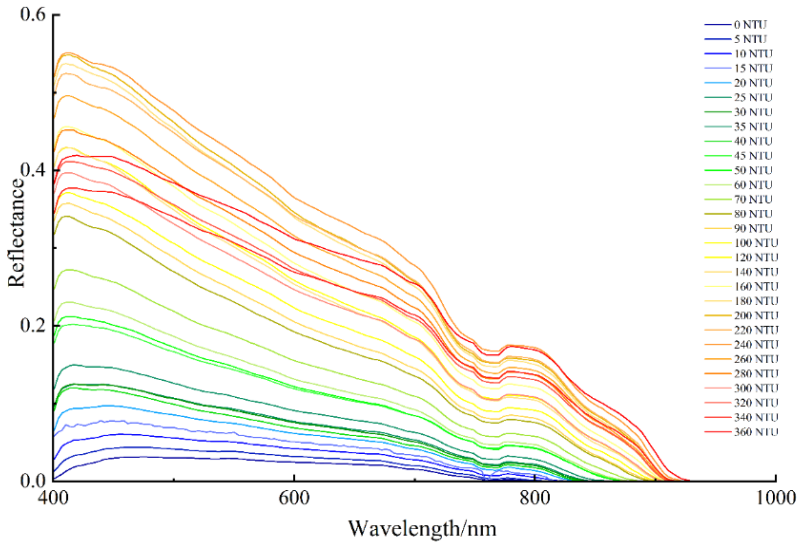

Figura 3-4 Cambios en las propiedades espectrales del agua a diferentes concentraciones de turbidez

Fuente: (Cui et al., 2022)

La concentración 0 NTU representa el agua limpia o pura, mientras que 360 NTU son valores de turbidez asociados a concentraciones altas de material orgánico o sedimentaria. A mayor concentración de turbidez, la reflectancia aumenta de forma significativa en las regiones de 500nm a 850nm.

También se encuentra el estudio realizado por Shen et al., 2021, donde realizaron curvas espectrales a diferentes concentraciones de turbidez (Figura 3-5)

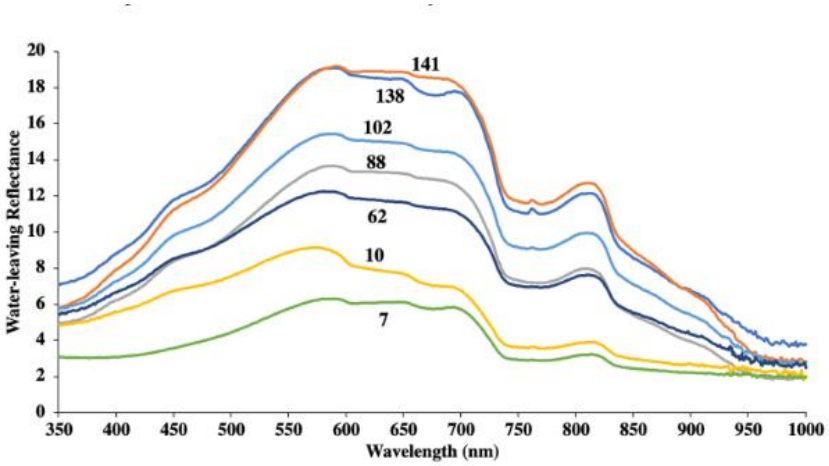

Figura 3-5 Cambios en las propiedades espectrales del agua a diferentes concentraciones de turbidez en un cuerpo de agua lentico

Fuente: (Shen et al., 2021)

Las longitudes de onda donde se presentan mayores reflectancias medidas en porcentaje van desde 400nm, hasta aproximadamente 850nm, es pertinente aclarar que estas reflectancias fueron calculadas en cuerpos de agua de más de 1 metro de profundidad, por lo que se asume que no hay cambios de reflectancias asociadas a la lámina de agua. Los estudios referidos a la estimación de turbidez en el agua consideran las bandas del espectro visible y del espectro infrarrojo cercano como el rededge dada al cambio presentado en estos rangos del espectro en función a la concentración de turbidez.

Por otro lado, los parámetros fisicoquímicos de calidad del agua como clorofila, nitratos, fosfatos y demanda química de oxígeno han sido analizados con imágenes multiespectrales de alta resolución capturadas con UAS (B. Chen et al., 2021; Niu et al., 2021; Xiao et al., 2022). En el estudio presentado por (Xiao et al., 2022) se presentan las

respuestas espectrales de estos parámetros de calidad del agua y de los índices espectrales NDVI, NDWI y NDWI2 denotados como V43,V44,V45 en la Figura 3-6.

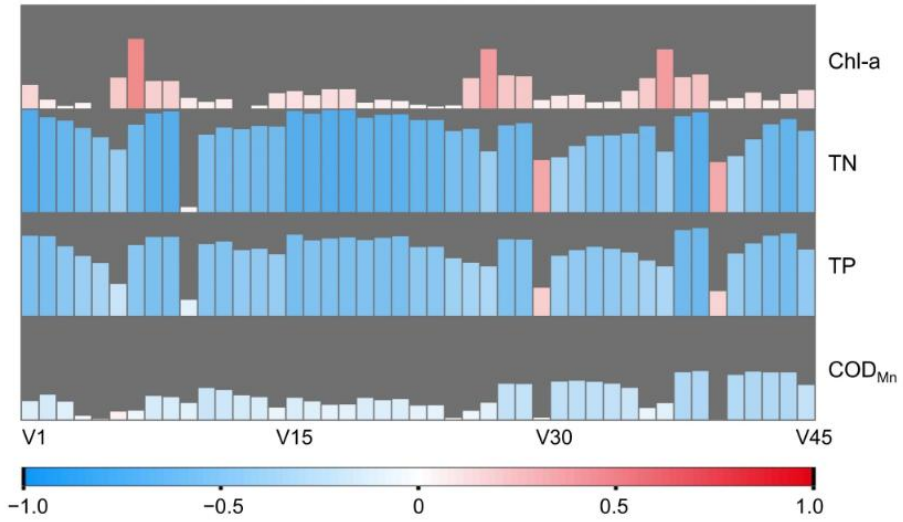

Figura 3-6 Respuestas espectrales de diferentes parámetros de calidad del agua

Fuente: (Xiao et al., 2022)

Cada parámetro tiene diferentes respuestas espectrales, por lo que el uso de índices y modelos para estimar las concentraciones de los parámetros de calidad del agua es imperante. Sin embargo, los índices de vegetación y de agua (NDVI y NDWI) cuyo calculo está relacionado con las longitudes de onda asociadas al espectro infrarrojo, verde y rojo, tienden a ser más sensibles a los cambios de concentración de nitratos, fosfatos, y clorofila, por lo que las respuestas espectrales en estos espectros cambian en función a las concentraciones de estos parámetros en un cuerpo de agua en particular.

Por otro lado Xiao et al., 2022 logró determinar las concentraciones de diferentes parámetros de calidad del agua en ríos, con errores medios cuadráticos desde 2mg/L hasta 0.8mg/L haciendo uso de diferentes algoritmos de inteligencia computacional como Random Forest y XGBoost e imágenes de UAS multiespectrales con resolución espectral de 5 bandas.

Finalmente, en el estudio presentado por Niu et al., 2021 se realizó modelamiento de nitratos, fosfatos y turbidez haciendo uso de imágenes de UAS hiperespectrales y algoritmos de redes neuronales artificiales, obteniendo errores medios cuadráticos entre 5mg/L hasta 0.05mg/L

3.3 Imágenes multiespectrales de UAS

Los UAS o drones se pueden definir como vehículos aéreos no tripulados que pueden ser manejados de forma remota o son autónomos en su vuelo y llevan carga útil, que puede ser letales como misiles balísticos, torpedos entre otros, y no letales como cámaras, celulares, y sensores especializados. Recientemente los UAS han sido fundamentales para desarrollar monitoreos ambientales, como evaluación de efectos por el cambio climático, manejo de cultivos, biodiversidad, calidad del agua entre otras muchas aplicaciones (Hassanalian & Abdelkefi, 2017).

Los UAS especializados en monitoreos ambientales tienen ciertas características, como georreferenciación cinemática en tiempo real, sensores de alta resolución espectral y radiométrica que son altamente sensibles a los cambios que se presentan en el ambiente. Sin embargo, cada sensor, tiene sus propiedades físicas únicas, como la curvatura del lente, desempeño de los filtros dispuestos en cada uno de los detectores, campo de visión instantáneo, distancia focal, entre otras (Sibanda et al., 2021).

Dentro de la amplia gama de sensores en la industria, para estudios ambientales y agrícolas se destaca el sensor RedEdge Micasense, el cual tiene reportados parámetros de calibración óptimos en estudios como el realizado por (Cao et al., 2019) donde estiman con precisión las longitudes de onda en las que captura el sensor, los anchos de banda de cada cañón del sensor, y pruebas de reflectancia en laboratorio para cada una de las bandas donde este sensor mostró altas correspondencias entre valores de reflectancia comparado con valores teóricos después de la calibración en comparación con otros sensores.

3.4 Índices espectrales y su relación con los parámetros de calidad de agua

Los índices espectrales se pueden definir como técnicas de realce de una imagen basado en las respuestas espectrales encontradas del objeto de interés. Generalmente los índices se utilizan para facilitar la interpretación de las propiedades del objeto de interés, excluyendo las superficies que no comparten respuestas espectrales similares (McFeeters, 1996)

En el estudio publicado por McFeeters, 1996 se presentó el índice NDWI, con el fin de delimitar superficies acuáticas y evaluar su calidad. Allí se mostró que el NDWI surge a partir de la relación entre las bandas con respuestas cercanas a los 547nm como la banda verde, y 863nm como la banda Red Edge o Infrarrojo cercano dependiendo del sensor, de esta manera se puede intensificar las coberturas acuáticas de una imagen y evaluar diferentes parámetros como la turbidez, nitratos, fosfatos, demanda química de oxígeno, entre otros.

Existen otros tipos de índices que sirven para determinar calidad del agua como los mostrados en el estudio de Robert et al., 2016 donde utilizaron el espectrorradiómetro de imágenes de media resolución MODIS con el fin de generar un modelo inverso para la determinación de la turbidez en cuerpos de agua ubicados en Burkina Faso – África determinando una fuerte correlación entre el cálculo del índice NIR/R y R-NIR con los valores de turbidez encontrados en campo.

Con relación a otros parámetros de calidad del agua, en el estudio presentado por Xiao et al., 2022 presenta diferentes índices espectrales y modelamiento utilizados para los determinar clorofila, fósforo total, nitrógeno total, y demanda química de oxígeno (Tabla 3-1)

Tabla 3-1: Índices espectrales y modelos asociados para estimar concentraciones de parámetros de calidad de agua.

Parámetro	**Índice espectral**	**Modelo**
Clorofila (Chl-a)	$\rho_{(475nm)} - \rho_{(670nm)}$	$y = 34.28\times (\rho_{(475nm)} - \rho_{(670nm)}) + 3.09$
Nitrógeno Total (TN)	$\rho_{(475nm)} + \rho_{(710nm)}$	$y = 13.55e{-}2.65*(\rho_{(475nm)} + \rho_{(710nm)})$
Fósforo Total (TP)	$(\rho_{(670nm)} - \rho_{(840nm)})/(\rho_{(670nm)} + \rho_{(840nm)})$	$y=0.058\times((\rho_{(670nm)} - \rho_{(840nm)}) /(\rho_{(670nm)} + \rho_{(840nm)}))-0.87$

Parámetro	Índice espectral	Modelo
Demanda Química de Oxigeno (COD)	$(\rho\ 2- \rho_{(840nm)})/(\rho_{(560nm)}+ \rho_{(840nm)})$	$y=11.44\times((\rho_{(560nm)}- \rho_{(840nm)}) /(\rho_{(560nm)}+ \rho_{(840nm)}))^2- 11.37\times((\rho_{(560nm)}- \rho_{(840nm)}) /(\rho_{(560nm)}+ \rho_{(840nm)}))+6.62$

Fuente: (Xiao et al., 2022)

Estos índices fueron construidos a partir de las respuestas espectrales encontradas en las bandas RGB, NIR y RedEdge de imágenes multiespectrales provenientes de UAV del estudio de (Xiao et al., 2022).

3.5 Modelamiento de parámetros de calidad de agua

Con la variedad de sensores remotos dispuestos en diferentes tipos de plataformas como satelitales y aerotransportadas, se ha dado la necesidad de establecer metodologías para obtener información precisa de diferentes parámetros de calidad de agua que sean precisas y den respuesta a necesidades particulares. La primera de ellas es el modelamiento empírico, el cual se fundamenta en generar regresiones estadísticas de cualquier grado polinomial basadas en datos tomados en campo y los niveles de reflectancia captados por el sensor remoto (Ouma et al., 2018). Es la más sencilla y simple de ejecutar y se puede complementar con diferentes análisis de selección de bandas o índices espectrales como puede ser el uso de los mínimos cuadrados parciales, sin embargo, la cantidad de muestras que se necesitan en campo para obtener altos niveles de exactitud es alta, así mismo estos modelos empíricos tienen bajas precisiones cuando se transfieren de un sensor a otro, por lo que son diseñados para ser utilizados con un único sensor.

También se encuentra el método analítico, el cual se fundamenta en el uso de modelos bio-ópticos y de transmisión de la radiación para modelar la distribución de la luz en la atmósfera y en los cuerpos de agua. El uso de estos modelos no es muy extendido dado que la compleja composición a nivel fisicoquímico en el agua hace que estos modelos

necesiten una gran cantidad de variables externas que afectan las propiedades de estos modelos de transmisión de la radiación (Gao et al., 2015b).

Igualmente existen los modelos semi-empíricos, que, son una concatenación entre el modelo empírico y analítico, el cual utiliza ciertos modelos de transmisión de la radiación preestablecidos a una regresión empírica, estos modelos necesitan una pequeña cantidad de muestras tomadas en campo para obtener altas precisiones en la determinación de parámetros fisicoquímicos(Yang et al., 2022).

Finalmente están los modelos basados en aprendizaje computacional, los cuales utilizan algoritmos implícitos que difieren de modelos anteriormente descritos, dado que no se puede obtener una expresión explícita de estos algoritmos y no utilizan ningún modelo físico de transmisión de la radiación. Los modelos más ampliamente utilizados son los de redes neuronales artificiales , que toman los valores de reflectancia de cada banda como parámetros de entrada y estima en cada pixel las concentraciones de los parámetros, sin embargo, se necesita una gran cantidad de muestras tomadas en campo, por lo cual otros algoritmos utilizado son máquinas de soporte vectorial y bosques aleatorios, los cuales son muy útiles cuando no es factible obtener gran cantidad de muestras de calidad de agua, pero computacionalmente son muy costosos (Yang et al., 2022).

En la Tabla 3-2 se muestran diferentes modelos para la estimación de parámetros de calidad del agua

Tabla 3-2: Referenciación de modelos para estimar parámetros de calidad de agua

Parámetro	**Sensor**	**Modelo**	**Ecuación**	**Referencia**
Turbidez	MODIS	Aprendizaje computacional	Redes Neuronales	(J. Chen et al., 2015)
	Gaiasky-mini2-VN	Empírico	$T = 1305 * ln\frac{\rho(707nm)}{\rho(541nm)} + 876.2$	(Cui et al., 2022)
Nitrógeno Total	OLI	Semi-Empírico	$NT = 0.116 + 2.071\left(\frac{\rho(655nm)}{\rho(562nm) + \rho(865nm)}\right)^{1.26477}$	(Li et al., 2017)
Fosforo Total	OLI	Semi-Empírico	$FT = -0.2 + 0.005e^{\frac{(\rho(nm443)+\rho(nm562)+\rho(nm655))}{\rho(nm583)}}$	(Li et al., 2017)
DQO	MERIS	Semi-Empírico	$DQO = 2.76 - 17.27\rho(485nm) + 71.15\rho(560nm) - 12.11\rho(660nm)$	(Gitelson et al., 2008)
Clorofila	OLI	Empírico	$C_{Chl-a} = -(16.2 \pm 1.8) + (136.2 \pm 3.2) * [\rho^{-1}(667nm) * \rho(748)]$	(Wang et al., 2004)

4. Materiales y métodos

4.1 Flujo de trabajo

Para poder desarrollar de forma adecuada los objetivos específicos del trabajo se planteó el siguiente flujo de trabajo donde se presentan cada una de las etapas a ejecutar para poder desarrollar las metodologías que estimen los parámetros de calidad de agua.

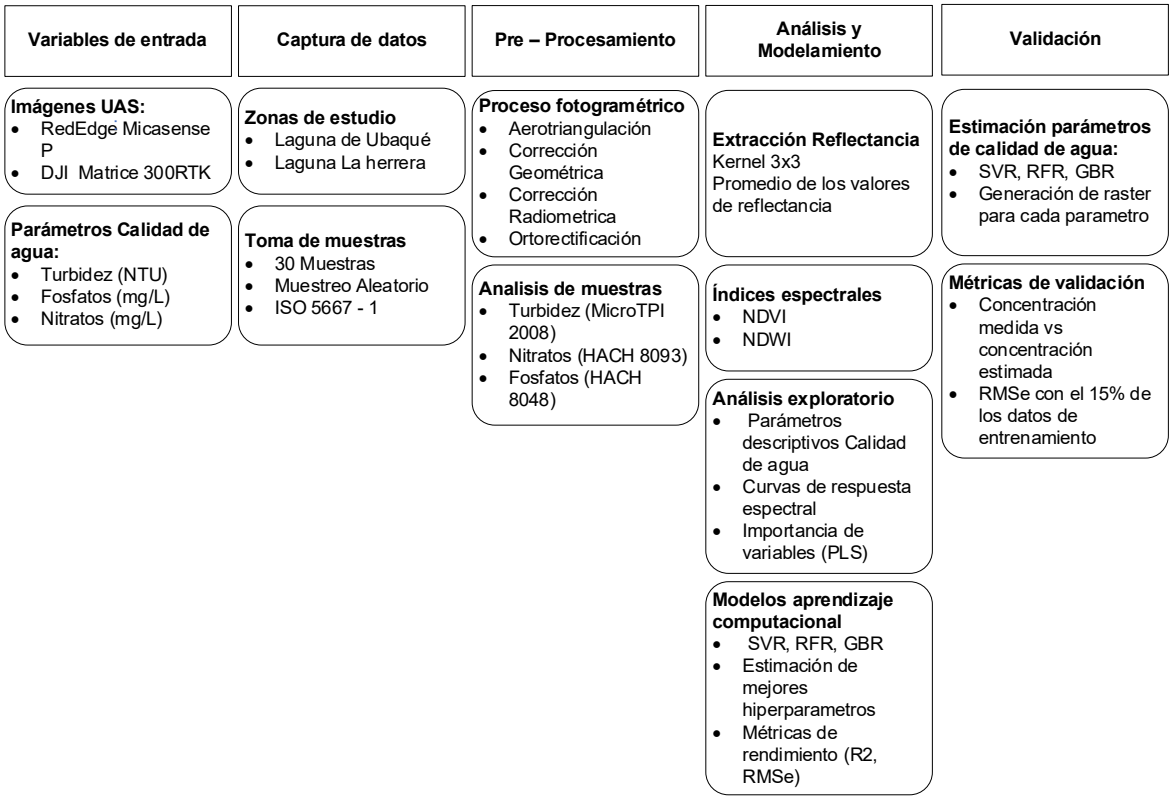

Figura 4-1 Diagrama metodológico para la estimación de parámetros de calidad de agua

4.2 Área de estudio

Se escogieron dos cuerpos de agua lénticos cuya calidad de agua fuera visiblemente diferente y fueran de fácil acceso garantizando que una de ellas estuviera en estado de conservación, por lo que se hizo una inspección inicial con imágenes de Sentinel 2, evidenciando cuerpos de agua en el departamento de Cundinamarca con valores altos y bajos de NDVI y NDWI escogiendo así la Laguna La Herrera y la Laguna de Ubaque.

La Laguna La Herrera ubicada en el municipio de Mosquera, departamento de Cundinamarca cuenta con una extensión de 287 hectáreas, profundidad media aproximada de dos metros y altitud de 2250 m.s.n.m. Esta declarada como reserva hídrica nacional por la Corporación Autónoma Regional de Cundinamarca sin embargo las zonas circundantes de la laguna tienen vocación minera a cielo abierto que genera deposición de solidos en la laguna por escorrentia por lo que tiene concentraciones altas de turbidez y de materia orgánica (Figura 4-2).

La laguna de Ubaqué, está ubicada en el municipio de Ubaque, departamento de Cundinamarca, tiene una extensión de 10 hectáreas, profundidad media de 3 metros y altitud de 1820 m.s.n.m. Es una zona de protección declarada por el Ministerio de Ambiente y Colombia. Sus alrededores son de vocación residencial, no se permiten vertimientos de aguas residuales sobre la laguna por lo que es un cuerpo de agua con baja incidencia de contaminación. Adicionalmente este cuerpo de agua ha sido sujeto de acciones de restauración por lo que la calidad del agua está en su estado ecológico natural (Figura 4-3).

Figura 4-2 Laguna La Herrera

Fuente: Elaboración Propia

Figura 4-3 Laguna de Ubaque

Fuente: Elaboración Propia

La ubicación espacial de las zonas elegidas para el estudio de muestran en la Figura 4-4.

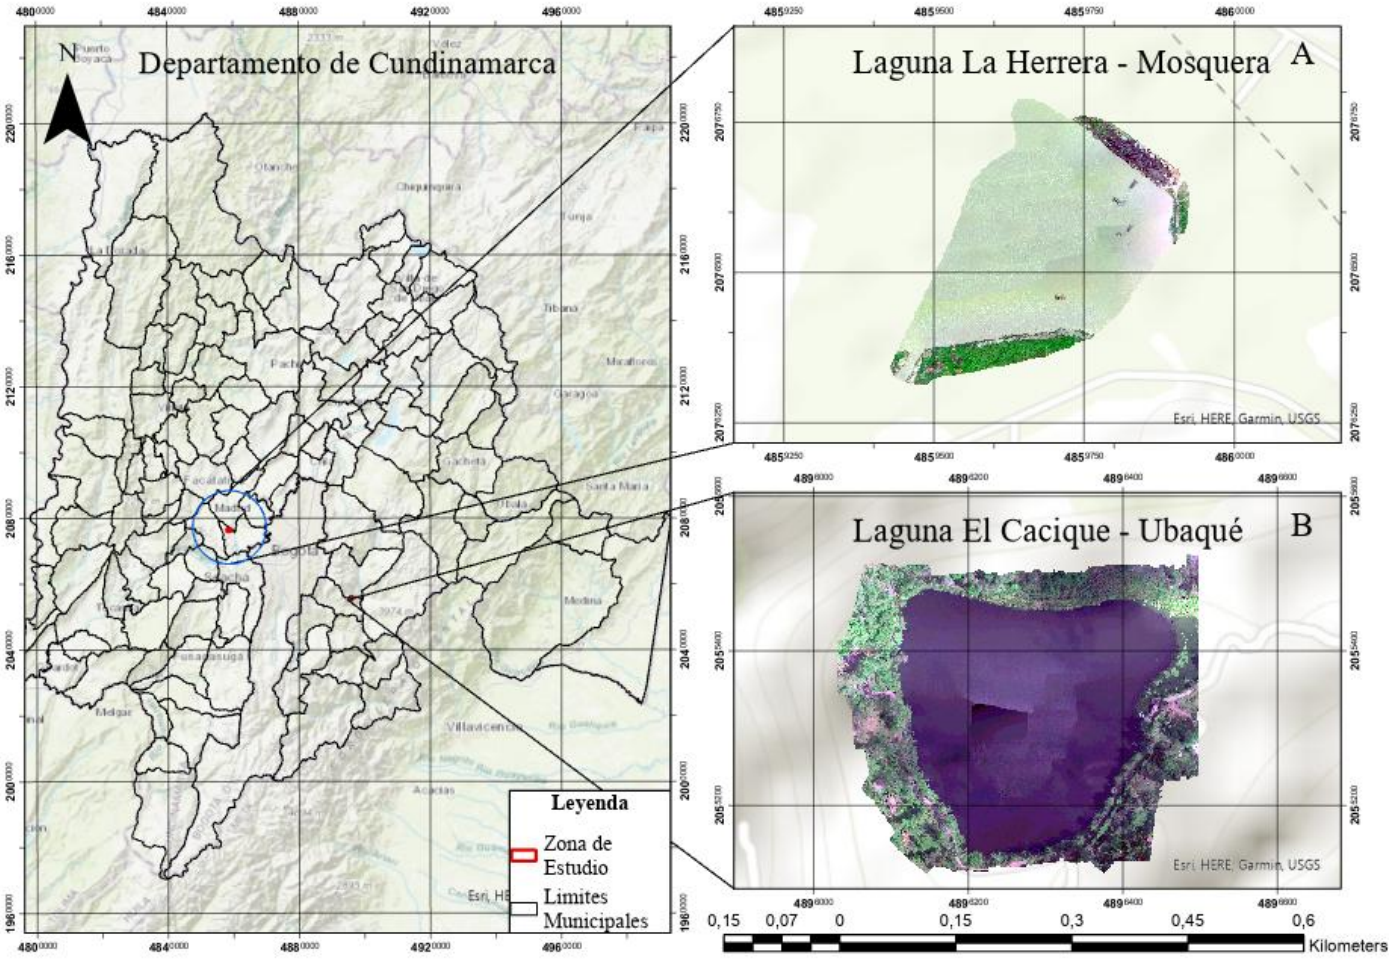

Figura 4-4 Zonas de estudio. ESPG: 9377

Fuente: Elaboración Propia

4.3 Variables de estudio

Las variables utilizadas fueron categorizadas como variables predictoras que hace referencia a los valores de reflectancia e índices espectrales calculados a partir del ortofotomosaico y variables respuesta que son las concentraciones de los parámetros de calidad de agua estimadas (Tabla 4-1).

Tabla 4-1 Variables utilizadas en el estudio

Variable	**Unidad**	**Tipo de variable**
Nitratos (NO_3-)	mg/L NO_3-	Respuesta
Fosfatos (PO_4^{3-})	mg/L PO_4^{3-}	Respuesta
Turbidez	Unidades Nefelométricas de Turbidez	Respuesta
Reflectancia en superficie banda roja	%	Predictora
Reflectancia en superficie banda azul	%	Predictora
Reflectancia en superficie banda verde	%	Predictora
Reflectancia en superficie banda RedEdge	%	Predictora
Reflectancia en superficie banda Infrarroja Cercana	%	Predictora
Índice NDVI	N/A	Predictora
Índice NDWI	N/A	Predictora

Fuente: Elaboración Propia

4.4 Adquisición de datos

- ### Toma de datos a partir de UAS

El UAS multirotor DJI Matrice 300 RTK fue utilizado con el sensor remoto multiespectral Micasense RedEdge P y la antena DJI RTK2 para capturar las imágenes en los cuerpos de agua lenticos de La Herrera y Ubaqué (Figura 4-5). Las especificaciones técnicas del sensor óptico utilizado y los rangos de longitudes de onda en las cuales captura el sensor se muestran en la Tabla 4-2 y Tabla 4-3 respectivamente.

Figura 4-5 Sistema UAS, Sensor y Antena Utilizado

Fuente: Elaboración Propia

Tabla 4-2 Especificaciones técnicas del sensor remoto Micasense RedEdge P

Parámetros	Multiespectral	Pancromática
Tamaño del pixel	3.45 µm	3.45 µm
Resolución	1456 x 1088 (1.58 MP por banda multiespectral)	2464 x 2056 (5.1MP banda pancromatica)
Radio de aspecto	4:03	6:05
Tamaño del sensor	6.3 mm diagonal	11.1 mm diagonal
Distancia Focal	5.5 mm	10.3 mm
Campo de visión	49.6° HFOV x 38.3° VFOV	44.5° HFOV x 37.7° VFOV
Resolución Radiométrica	12-bit	12-bit
GSD a 120 m	7.7 cm/pixel	3.98 cm/pixel
GSD a 60 m	3.85 cm/pixel	1.99 cm/pixel

Fuente: (Micasense, 2021)

Tabla 4-3 Rangos de longitudes de onda de medición en el sensor Micasense RedEgdeP

Canal	Longitud de onda central	Ancho de longitud de onda
Blue	475 nm	32 nm
Green	560 nm	27 nm
Red	668 nm	16 nm
Red Edge	717 nm	12 nm
Near infrared	842 nm	57 nm

Fuente:(Micasense, 2021)

El posicionamiento de las imágenes fue generado a partir del uso de la antena DJI RTK 2, la cual rastrea en tiempo real las coordenadas a partir de la constelación GPS y ajusta los isocentros de las imágenes capturadas con precisión centimétrica, por lo cual no se tomaron puntos de control terrestre en ninguno de los vuelos.

El UAS, fue calibrando en sus sistemas de medición inercial y brújula a partir de la aplicación DJI Pilot 2 previo los vuelos efectuados sobre los cuerpos de agua como se evidencia en la Figura 4-6.

Figura 4-6 Calibración del IMU y brújula UAS DJI Matrice 300 RTK

Fuente: Elaboración Propia

Los vuelos fueron efectuados en las siguientes fechas para la Laguna de Ubaque y La Herrera respectivamente: 10/02/2024 -10:30am, 06/04/2024 – 9:30am. La altura para la toma de las imágenes fue de 150m por lo que el tamaño de píxel en terreno estimado fue de 10cm. Las imágenes se adquirieron con un traslape de 80%, para evitar la presencia de huecos fotogramétricos. Las horas de captura de información garantizaron un bajo a nulo efecto espejo-especular de la luz solar sobre el agua y la comparación entre ambas zonas de estudio.

- **Toma de datos en campo de parámetros de calidad del agua.**

Se realizaron muestreos aleatorios georreferenciados con la antena Trimble Catalyst DA2 en la Laguna la Herrera y Laguna de Ubaque, simultaneo a la toma de las imágenes, para lo cual se dividió el área de estudio en grillas de 10 metros x 10 metros y mediante un algoritmo de aleatoriedad de grillas se seleccionaron las muestras necesarias para obtener un nivel de confianza del 95% y una desviación estándar del 5% según lo mostrado en la ISO 5667-1. Las muestras fueron tomadas haciendo uso de una lancha dispuesta por un contratista de la Corporación Autónoma Regional de Cundinamarca (Figura 4-7). Se realizó un muestreo puntual superficial sobre la laguna de forma superficial para cada uno de los puntos. Estas muestras fueron analizadas con el turbidímetro MicroTPI 20008 y con el espectrofotómetro HACH DR1900, utilizando el método HACH 8093 para nitratos y HACH 8048 para fosfatos. Se realizaron diluciones 1:100 para poder estimar los fosfatos mediante este método. Las muestras fueron refrigeradas a 4°C para llevar a cabo los análisis fisicoquímicos de nitratos, fosfatos. En la Figura 4-8 la espacialización de los puntos de muestreo.

Figura 4-7 Muestreo de agua realizado (A,B Muestreo Laguna la Herrera), (C,D Muestreo en Laguna de Ubaqué)

Fuente: Elaboración Propia

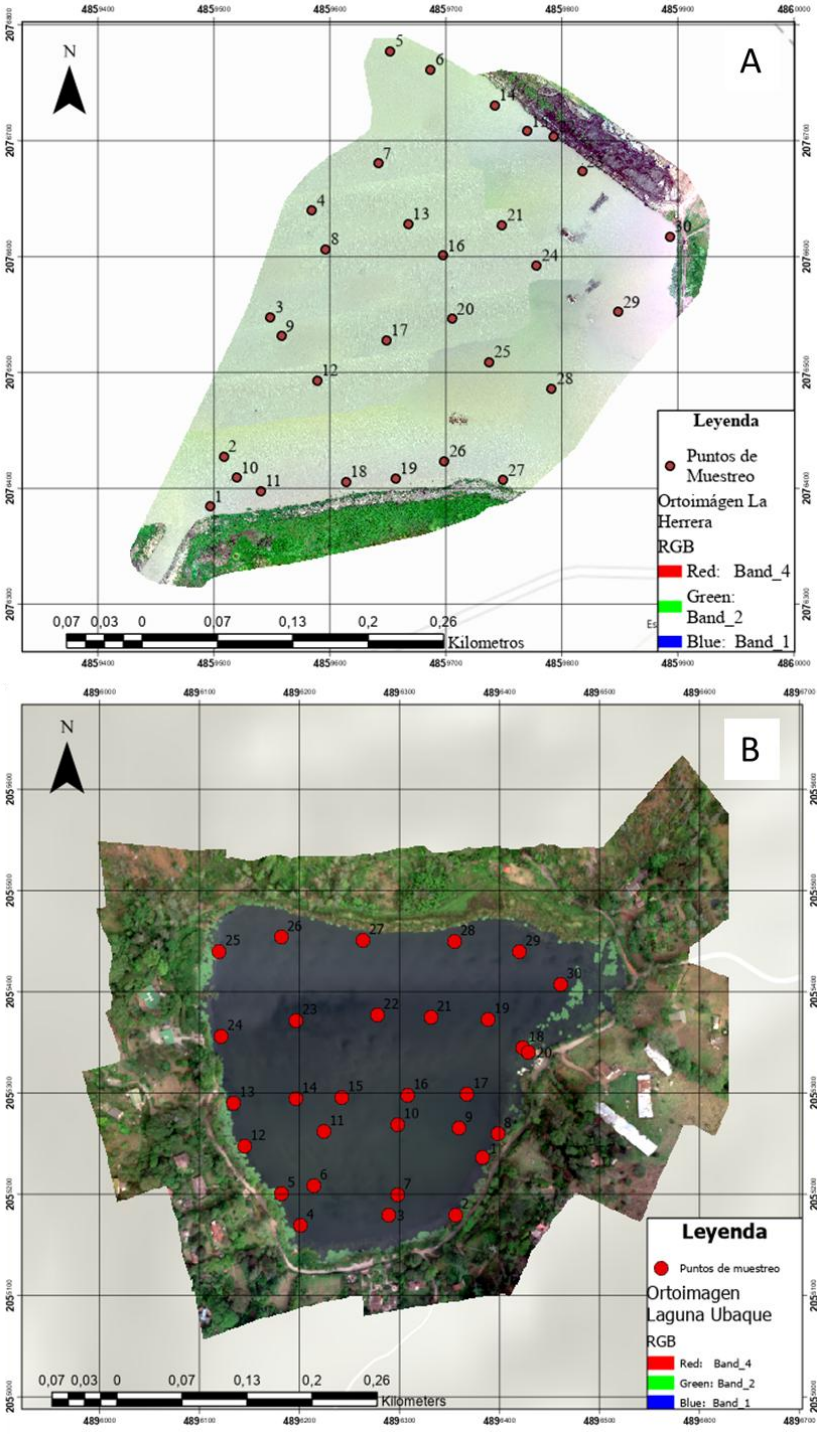

Figura 4-8 Puntos de muestreo en las zonas de estudio (A. Laguna La Herrera, B. Laguna de Ubaque)

Fuente: Elaboración Propia

4.5 Pre – Procesamiento

Las imágenes UAV multiespectrales fueron preprocesadas radiométricamente para convertir los niveles digitales crudos, en valores de reflectancia en superficie según la ecuación 4-1 también consignadas por el proveedor de RedEdge Micasnese en sus especificaciones técnicas(Micasense, 2021).

$$L = V(x,y) * \frac{a_1}{g} * \frac{p - p_{BL}}{t_e + a_2 y - a_3 t_e y} \quad (4\text{-}1)$$

Donde

- **p** es el valor crudo del píxel normalizado (encontrados en el metadato de las imágenes)
- $\mathbf{p_{BL}}$ es el valor crudo negro del píxel normalizado (encontrados en el metadato de las imágenes)
- $\mathbf{a_1}$, $\mathbf{a_2}$, $\mathbf{a_3}$ son los coeficientes de calibración radiométrica.
- **V(x,y)** es la función polinomial de vignette para un pixel en una posición definida x,y.
- $\mathbf{t_e}$ es el tiempo de exposición de la imagen (encontrado en el metadato de las imágenes)
- **g** es el ajuste de ganancia del sensor.
- **L** es la reflectancia en superficie.

Posteriormente, se ejecutó el procesamiento fotogramétrico en el software Agisoft Metashape Pro v2.1.0 (build 17532), corrigiendo geométricamente cada imagen mediante las orientaciones internas y externas obtenidas del sistema de posicionamiento RTK integrado en el UAS DJI Matrice 300. La alineación de las imágenes crudas se configuró con un nivel de precisión ‘muy alto’, incorporando puntos de control terrestre y emparejamiento guiado de imágenes. El modelo digital de superficie (MDS) se generó utilizando puntos de apoyo con extrapolación espacial para corregir áreas con deficiencias de alineación. La ortoimagen se construyó a partir del MDS y la alineación de las imágenes, aplicando parámetros de interpolación para rellenar vacíos y refinamiento de líneas de costura para optimizar la homogeneidad radiométrica. Finalmente, se implementó la e

ecuación 4-3 para completar la calibración radiométrica de la ortoimagen resultante.

- **Extracción de los valores de reflectancia a partir de los puntos de muestreo**

La extracción de los valores de reflectancia sobre la ortoimagen fue a partir de la definición de una ventana o kernel de tamaño 3 × 3 que coincide con cada uno de los puntos de muestreo. El valor promedio de cada kernel se utiliza para establecer la correlación con los parámetros de calidad del agua medidos y los índices espectrales calculados (Figura 4-9).

$\rho 1$	$\rho 2$	$\rho 3$
$\rho 4$	$\rho 5$ m	$\rho 6$
$\rho 7$	$\rho 8$	$\rho 9$

Figura 4-9 Kernel utilizado para el cálculo de las reflectancias medias en cada punto de muestreo

Fuente: Elaboración Propia

4.6 Análisis y modelamiento

- **Índices Espectrales**

El índice de vegetación normalizado (NDVI), y el índice de agua normalizado I fueron calculados en el software ArcGIS Pro V3.3.2 utilizando la ecuación 4-2 y 4-3 en función a los rangos de longitudes de onda que captura el sensor Micasense RedEdge P.

$$NDVI = \frac{\rho(842nm)_{NIR} - \rho(668nm)_{Red}}{\rho(842nm)_{NIR} + \rho(668nm)_{Red}} \quad (4\text{-}3)$$

$$NDWI = \frac{\rho(560nm)_{green} - \rho(842nm)_{NIR}}{\rho(560nm)_{green} + \rho(842nm)_{NIR}} \quad (4\text{-}3)$$

- ## Análisis exploratorio de datos

Se realizó un análisis exploratorio de las variables predictoras extraídas de las ortoimágenes, índices espectrales y parámetros de calidad de agua para cada punto de muestreo con la finalidad de evaluar valores atípicos, correlaciones entre las variables predictoras y tendencias a partir de la librería Seaborn de Python. Posteriormente para extraer las variables que más influyen en la estimación de las variables respuesta del estudio, se realizó una regresión PLS. Este método elimina la colinealidad entre las variables predictoras y permite determinar de manera precisa la contribución individual de cada variable en la estimación de las variables respuesta. El análisis se ejecutó en el software The Unscrambler X® para cada punto de muestreo.

- ## Generación de modelos de aprendizaje computacional

Para desarrollar el modelo de regresión se tuvieron como base las variables predictoras y respuesta mostradas en la Tabla 4-1. Se emplearon como técnicas principales de modelado, SVR, RFR y GBR. SVR es particularmente útil para capturar relaciones no lineales, mientras que RFR y GBR proporciona información sobre la importancia de las variables predictoras y maneja eficazmente distribuciones complejas de pueden tener los datos.

Los datos de calidad de agua tomados en campo se dividieron en conjuntos de entrenamiento (85%) y validación (15%), y las variables predictoras se normalizaron utilizando escalado Estándar. Se realizó una validación cruzada para evaluar el rendimiento del modelo utilizando las métricas de R^2, RMSE y MAE.

La implementación se realizó en Python, utilizando las librerías Rasterio, Geopandas, Scikit-learn y NumPy (Anexo 1). Para la visualización y análisis espacial adicional, se utilizó software GIS ArcGIS Pro.

La configuración optima de hiperparametros para entrenar cada modelo de aprendizaje computacional, fue evaluada a partir del método GridSearchCV de la librería Scikit-Learn, la cual prueba diferentes combinaciones de hiperparametros y establece cuales son las mejores para predecir cada parámetro de calidad de agua.

Una vez entrenados y validados los modelos de regresión, se realizan predicciones a nivel de píxel aplicando los modelos entrenados a la ortoimagen generada para la zona de estudio de Laguna La Herrera. Los valores de las bandas y los índices de cada píxel se utilizan como variables de entrada, generando un ráster donde cada píxel representa la concentración predicha de turbidez, nitratos y fosfatos. El resultado se guarda en formato GeoTIFF.

4.7 Validación de modelos

La validación de los modelos se llevó a cabo utilizando los datos capturados en la Laguna de Ubaqué y la Herrera, escogidos aleatoriamente. Para ello, se generó un ráster en el que se predijeron las concentraciones de calidad del agua, permitiendo la espacialización de dichas concentraciones en cada uno de los puntos de muestreo establecidos en la laguna.

El procedimiento de validación consistió en la comparación de los valores de calidad del agua estimados por el modelo con los valores obtenidos directamente en campo a partir de mediciones in situ. Esta comparación se realizó en cada uno de los puntos de muestreo, evaluando la precisión y confiabilidad de los modelos generados.

Adicionalmente para cada punto de muestreo se calculó la diferencia entre el valor de calidad de agua tomado en campo con el generado en el ráster para así evaluar el comportamiento punto a punto del modelo generado.

Finalmente, para cuantificar el nivel de error entre los valores predichos y los valores medidos en campo, se calculó el RMSE. Estas métricas permitieron evaluar el grado de concordancia entre los datos modelados y los datos reales, facilitando la identificación de posibles sesgos o variaciones en la precisión de las predicciones en distintas zonas de la laguna.

5. Resultados

5.1 Análisis exploratorio de datos

Los parámetros de calidad de agua fueron comparados entre las zonas de muestreo con la finalidad de evidenciar las diferencias en las concentraciones de turbidez, fosfatos y nitratos demostrando así los diferentes estados de conservación de ambos cuerpos de agua. En la Figura 5-1 se muestran las distribuciones de los parámetros de calidad de agua analizados y en la Tabla 5-1 los estadísticos generales de las concentraciones encontradas.

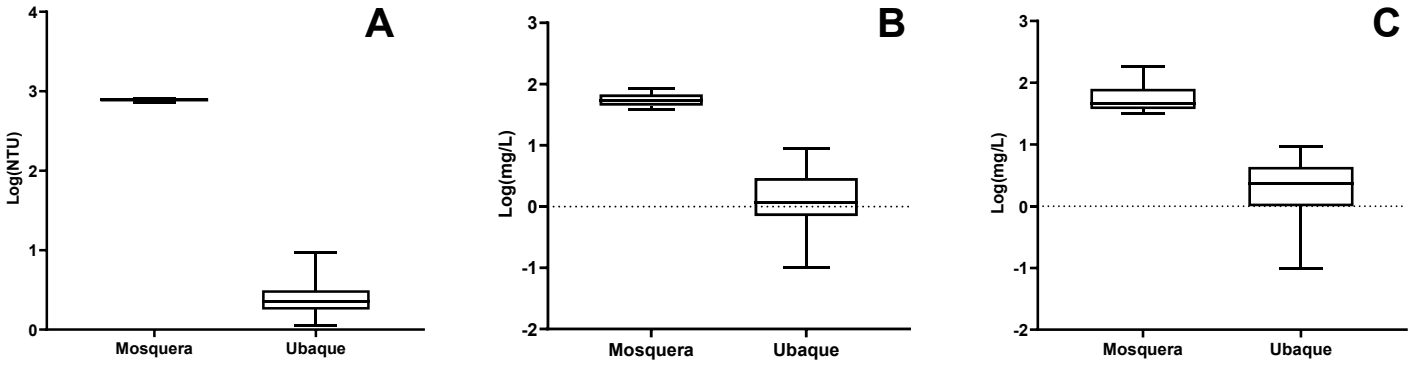

Figura 5-1 Distribución en las concentraciones de los parámetros de calidad de agua en las zonas de estudio (A. Turbidez, B. Nitratos, C. Fosfatos)

Tabla 5-1 Estadísticas generales de los parámetros de calidad de agua

Zona de estudio	**Mosquera**			**Ubaque**		
Parámetro	Media	Mediana	Desviación estándar	Media	Mediana	Desviación estándar
Turbidez	774,99	778,35	27,28	2,93	2,235	1,94
Nitratos	56,31	54,25	13,12	2,24	1,2	2,35
Fosfatos	60,34	46	31,52	2,70	2,3	2,17

En cuanto a los tres parámetros de calidad de agua, se encontró que las concentraciones obtenidas varían significativamente entre las zonas de estudio, lo cual visualmente es contrastado con la Figura 4-2 y Figura 4-3 donde se evidencia la sedimentación proveniente de las canteras a cielo abierto en la Laguna La Herrera y el estado de conservación natural de la Laguna de Ubaque.

La Figura 5-2 muestran los coeficientes de correlación de Pearson existentes entre las variables predictoras y los parámetros de calidad de agua. A partir de este análisis, se encontró que tanto los índices espectrales como los valores de reflectancia presentan una alta correlación entre sí, lo que indica que muchas de estas variables pueden estar proporcionando información redundante. La presencia de colinealidad puede afectar negativamente la exactitud y estabilidad de los modelos predictivos, dificultando la interpretación de los efectos individuales de cada variable. Por esta razón la importancia de las variables predictoras se generó a partir de la regresión PLS, que reduce la dimensionalidad del conjunto de datos mientras se mantiene la mayor cantidad de información relevante posible. A través de este método, se identificaron y seleccionaron las variables que más contribuyen a la predicción de los parámetros de calidad del agua eliminando aquellas que generaban colinealidad y optimizando el modelo predictivo.

Por otro lado, se evidencia que los coeficientes de correlación encontrados para las variables respuesta no son altos para ninguna variable predictora, lo que indica que las relaciones entre la reflectancia calculada y las concentraciones de calidad de agua no tienen un comportamiento lineal, generando así la necesidad de utilizar modelos robustos que puedan comprender las asociaciones entre estas variables.

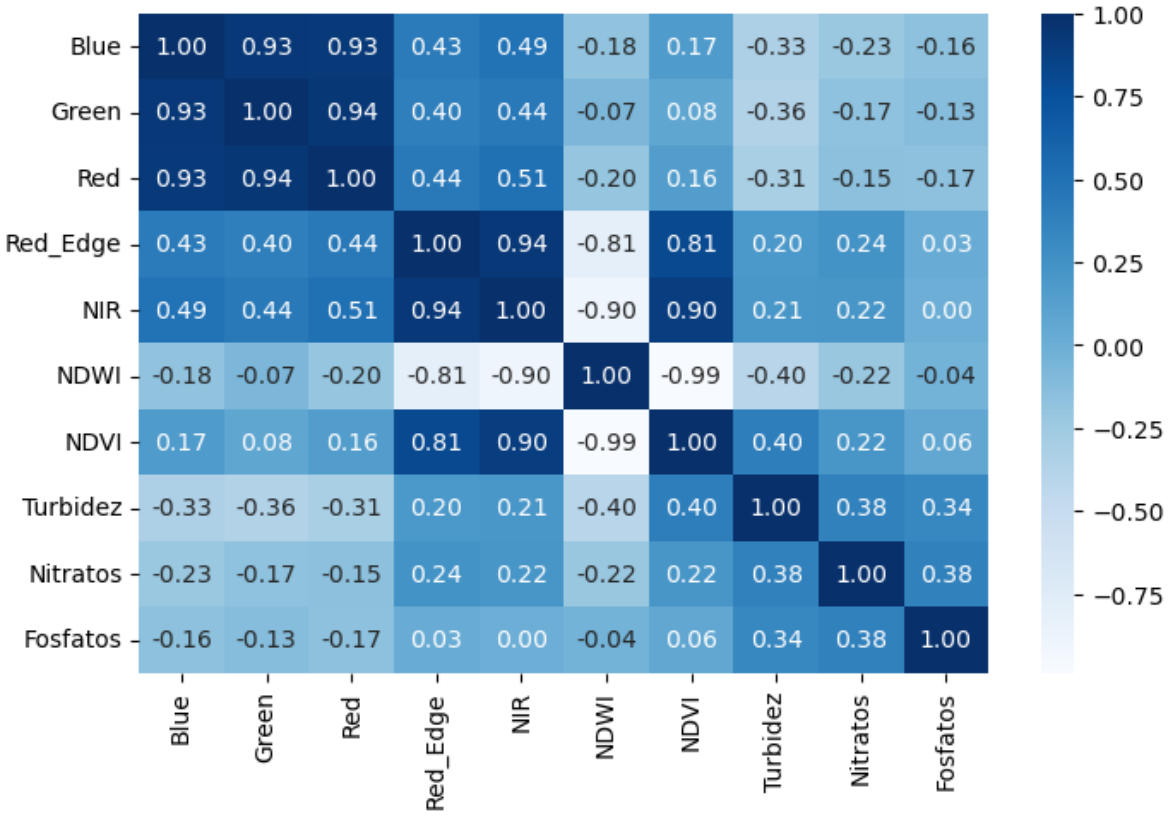

Figura 5-2 Tabla de correlación de Pearson entre las variables de estudio

Fuente: Elaboración Propia

5.2 Estimación de las importancias de las variables predictoras

El cálculo de la importancia de las variables fue calculado mediante la regresión PLS, que extrae las variables que aportan mayoritariamente a la explicación de la varianza y estimación en cada punto muestreado de calidad de agua. Estos valores de importancia se muestran en la Figura 5-3 para cada zona de estudio y parámetro de calidad de agua.

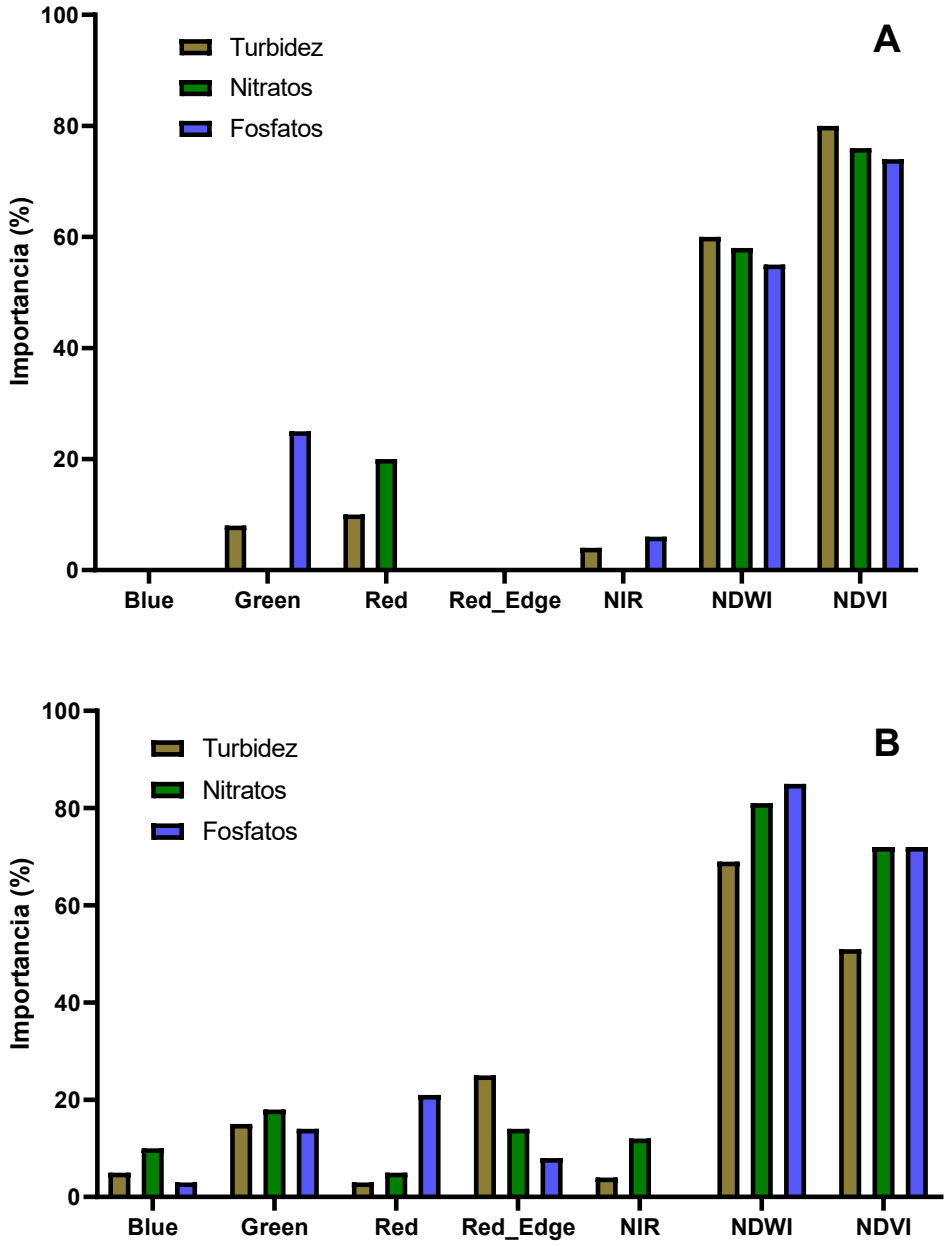

Figura 5-3 Importancia de las variables predictoras para la estimación de parámetros de calidad de agua (A. Laguna La Herrera, B. Laguna de Ubaqué)

Fuente: Elaboración Propia

Los resultados obtenidos indican que los índices espectrales fueron los predictores más relevantes para la estimación de la turbidez, los nitratos y los fosfatos dentro de ambas lagunas (Figura 5-3). En particular, los índices espectrales asociados a la reflectancia en el visible y el infrarrojo cercano demostraron una alta sensibilidad en la detección de variaciones en la calidad del agua, lo que sugiere que estas longitudes de onda capturan con precisión cambios en la composición del agua. Estos índices reflejan eficazmente la presencia de partículas suspendidas, materia orgánica y otros compuestos que influyen en los niveles de turbidez y concentración de nutrientes, convirtiéndolos en indicadores clave para la evaluación de estos parámetros.

Además, los resultados muestran que las bandas del infrarrojo medio y del infrarrojo cercano fueron las menos significativas en la estimación de la calidad del agua, lo que sugiere que estas longitudes de onda presentan una menor sensibilidad para detectar cambios en comparación con los índices espectrales derivados de bandas en el visible y el borde rojo. Esto puede explicarse porque las interacciones de la radiación en estas bandas con el agua y los compuestos disueltos no generan contrastes suficientemente marcados para ser utilizados como predictores eficientes. Por lo tanto, la selección de índices espectrales derivados de longitudes de onda en el visible y el borde rojo resulta más adecuada para modelar la calidad del agua, proporcionando una base sólida para el desarrollo de herramientas de monitoreo basadas en teledetección y mejorando la capacidad de análisis de los ecosistemas acuáticos.

5.3 Potencial de las imágenes UAS para estimar parámetros de calidad de agua.

A partir de los vuelos realizados en las distintas zonas de estudio, se generaron ortoimágenes de alta resolución con un tamaño de píxel aproximado de 2.5 cm. Estas imágenes permiten un análisis detallado de las características superficiales de los cuerpos de agua evaluados, proporcionando información clave sobre su reflectancia y composición.

Desde un análisis visual preliminar, se observa que la radiometría registrada para las superficies de agua presenta diferencias entre las zonas de estudio (Figura 5-4). Esta variabilidad se refleja en el color de las imágenes obtenidas, lo que sugiere cambios en la

composición del agua y, por ende, en los valores de reflectancia asociados a cada cuerpo de agua. Dichas diferencias en la reflectancia están estrechamente relacionadas con las concentraciones de los parámetros fisicoquímicos analizados, lo que indica que cada laguna posee características propias en cuanto a calidad y composición fisicoquímica.

En el caso específico de la Laguna La Herrera, se evidenciaron valores de reflectancia más elevados en comparación con la Laguna de Ubaque. En esta laguna, los valores de reflectancia se encontraron dentro de un rango de 0.3 a 0.7 en las bandas analizadas, lo que sugiere una mayor presencia de partículas en suspensión, sedimentos o incluso contaminantes. Por otro lado, en la Laguna de Ubaque, los valores de reflectancia oscilaron entre 0.05 y 0.3, lo que indica un agua con menor cantidad de partículas en suspensión y posiblemente de mayor transparencia.

Al analizar el Índice de Vegetación de Diferencia Normalizada (NDVI), se identificó que la Laguna de Ubaque presentó los valores más bajos, alcanzando -0.84. Según Fung & Siu (2000), este rango es característico de cuerpos de agua con bajos índices de sedimentación, lo que sugiere una menor carga de material orgánico e inorgánico en suspensión. En contraste, la laguna La Herrera mostró un valor mínimo de NDVI de -0.28, lo que indica una mayor presencia de sedimentos en el agua y, por ende, un ecosistema con mayores niveles de materia en suspensión.

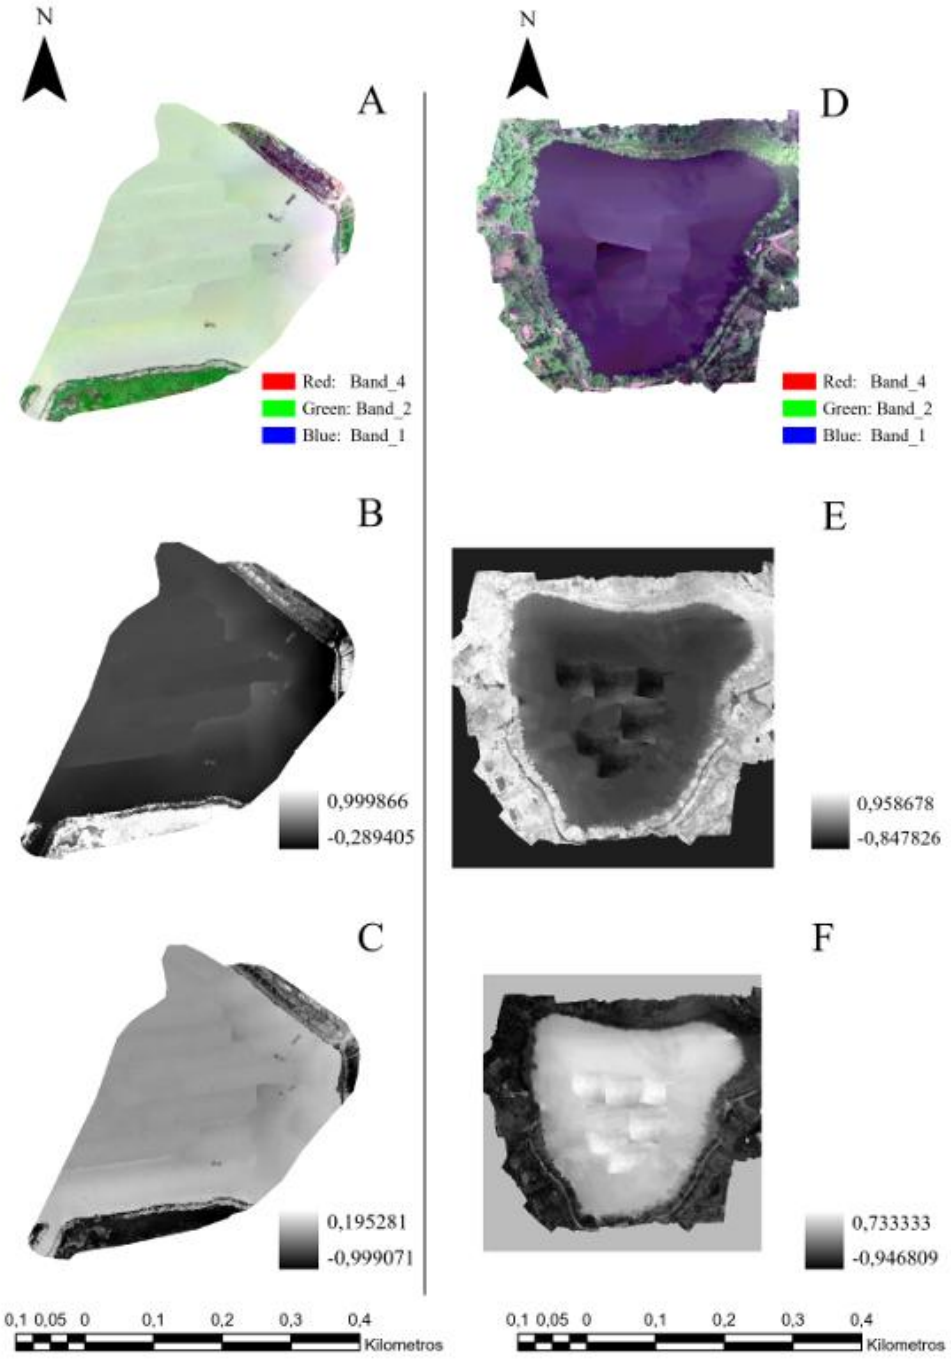

Figura 5-4 Ortoimagenes e índices espectrales generados de las áreas de estudio. (A. Ortoimagen Laguna La Herrera, B. Índice NDVI Laguna La Herrera, C. Índice NDWI Laguna La Herrera. D. Ortoimagen Laguna Ubaqué, E. Índice NDVI Laguna Ubaqué, F. Índice NDWI Laguna U)

Fuente: Elaboración Propia

En cuanto al NDWI, los resultados evidenciaron diferencias entre las dos lagunas estudiadas. La Laguna de Ubaque registró los valores más altos de NDWI, alcanzando un máximo de 0.73, lo que, de acuerdo con lo reportado por Cui et al. (2022), está asociado con menores niveles de turbidez y mayor claridad del agua. Por el contrario, la Laguna La Herrera presentó valores máximos de NDWI de 0.19, lo que sugiere una mayor concentración de turbidez, presencia de sólidos disueltos y otros posibles contaminantes asociados a las actividades de minería a cielo abierto que inciden en la turbidez, nitratos y fosfatos por la escorrentia de los sedimentos a la laguna.

Por otro lado, se evaluó la respuesta espectral de la turbidez en los diferentes rangos de longitudes de onda en la cual mide el sensor RedEdge Micasense P (Tabla 4-3), encontrando que los valores más altos de respuesta espectral se concentraron en la banda roja (Red), el borde rojo (Red Edge) y el infrarrojo cercano (NIR), lo que indica una mayor reflectancia en estas longitudes de onda (Figura 5-5).

Además, se identificó que a medida que aumentaba la turbidez del agua, los valores de reflectancia también se incrementaban. Esta relación se debe a la dispersión de la luz causada por las partículas suspendidas, lo que genera una mayor cantidad de radiación reflejada en comparación con cuerpos de agua más claros o menos turbios.

Al comparar las concentraciones de turbidez obtenidas en laboratorio con los valores de reflectancia capturados por el sensor remoto en los cinco rangos de longitudes de onda analizados, se observó una correspondencia directa. En particular, en las bandas del espectro electromagnético evaluadas, los valores más altos de reflectancia coincidieron con las zonas de mayor turbidez registradas en las mediciones de campo. Este comportamiento espectral sugiere una influencia de la composición del agua en la reflectancia medida, especialmente en las bandas del rojo, Red Edge e infrarrojo cercano, donde se registraron las mayores diferencias entre los puntos analizados.

Finalmente se evidencia que la reflectancia encontrada para la Laguna de Ubaque es menor que en la Laguna La Herrera, mostrando demostrando así que la reflectancia está asociada a la concentración de contaminantes en el agua, evidenciando el potencial de las imágenes multiespectrales para la estimación de estos parámetros.

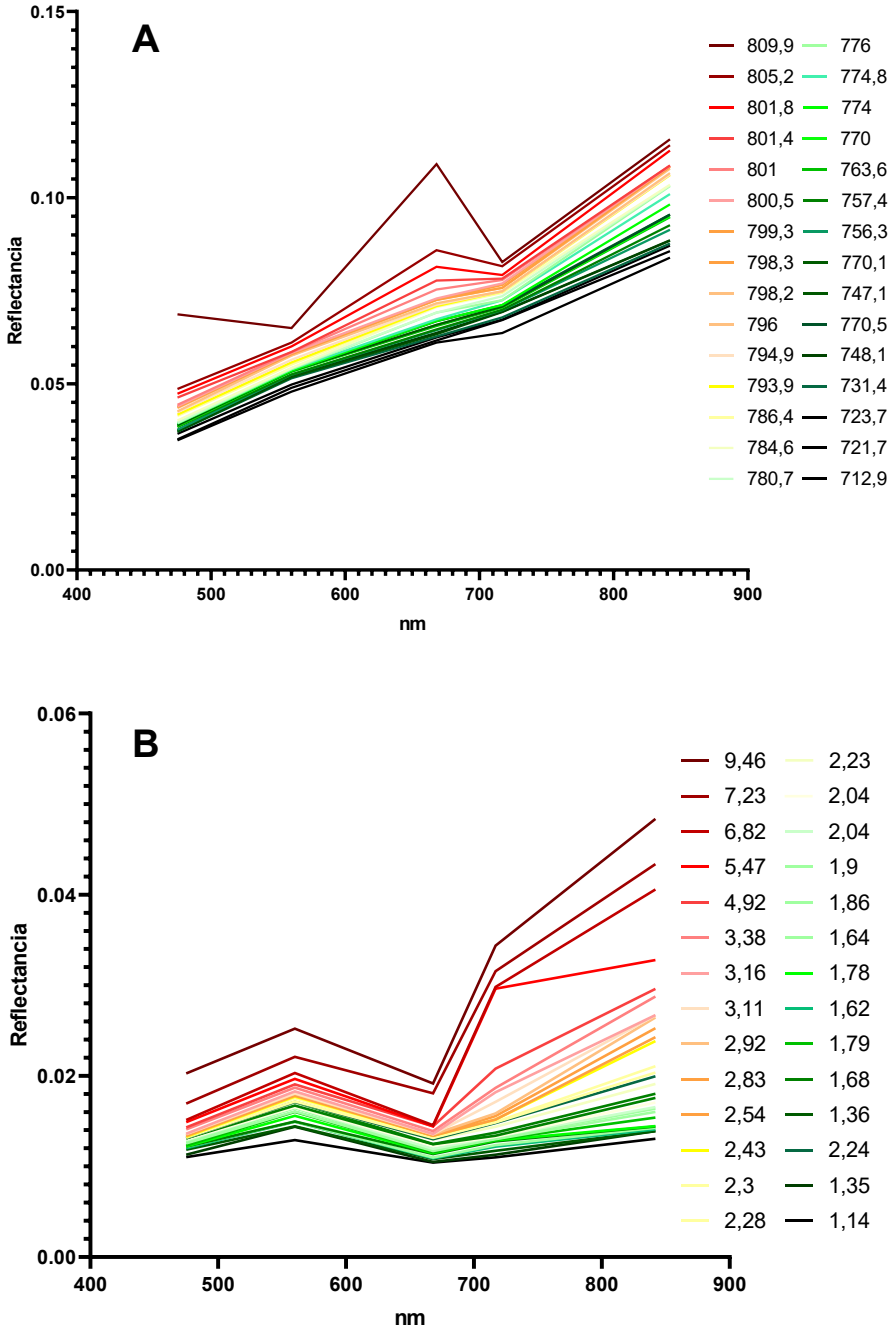

Figura 5-5 Respuestas espectrales del agua en diferentes concentraciones de Turbidez (A. Laguna La Herrera, B. Laguna de Ubaque)

Fuente: Elaboración Propia

5.4 Desempeño de los algoritmos de aprendizaje computacional

Los modelos se aprendizaje computacional fueron entrenados utilizando los índices espectrales de NDVI y NDWI según lo mostrado en el inciso 5.3. Para los modelos de SVM, RFR y GBR se estimaron los mejores hiperparametros para estimar cada parámetro de calidad de agua en función a la zona de estudio con los cuales fueron entrenados los modelos finales de estimación (Tabla 5-1).

Para el modelo SVR, se ajustaron los hiperparámetros "C", "epsilon" y "kernel". Se probaron valores de "C" en el rango de [0.1, 1, 10, 100], identificándose que el valor óptimo para todas las variables fue 100, lo que sugiere que un margen más amplio para el margen de error del modelo contribuye a mejorar su desempeño en esta aplicación. En cuanto al hiperparámetro "epsilon", que controla la tolerancia al error en la función de pérdida, se evaluaron los valores [0.01, 0.1, 1], encontrando que 0.01 fue el mejor para nitratos, mientras que para fosfatos y turbidez los valores óptimos fueron 0.1 y 1, respectivamente. Respecto al "kernel", que define la función utilizada para transformar los datos en un espacio de mayor dimensión, se probaron los valores ['rbf', 'linear', 'poly'], determinándose que "poly" fue la mejor opción para la predicción de nitratos y fosfatos, mientras que "rbf" mostró un mejor desempeño en la predicción de turbidez.

Por otro lado, para el modelo GBR, se ajustaron los hiperparámetros "n_estimators" y "learning_rate". En el caso de "n_estimators", que define el número de árboles en el ensamble, se evaluaron valores de [100, 200, 300], seleccionándose 100 como el óptimo para nitratos y fosfatos, mientras que, para turbidez, el mejor resultado se obtuvo con 200 estimadores. En cuanto a "learning_rate", que controla la contribución de cada árbol en el modelo, se probaron valores de [0.01, 0.1, 0.2], encontrándose que 0.2 fue la mejor opción para los tres parámetros de calidad del agua.

Tabla 5-2 Hiperparametros escogidos para cada parámetro de calidad de agua

Laguna La Herrera					
Modelo	**Hiperparametros**	**Valores probados**	**Mejor Valor (Nitratos)**	**Mejor valor (Fosfatos)**	**Mejor valor (Turbidez)**
SVR	C	[0.1, 1, 10, 100]	100	100	100
	epsilon	[0.01, 0.1, 1]	0,01	0,1	1
	kernel	['rbf', 'linear', 'poly']	poly	poly	rbf
GBR	n_estimators	[100, 200, 300]	100	100	200
	learning_rate	[0.01, 0.1, 0.2]	0,2	0,2	0,2
	max_depth	[3, 4, 5]	4	4	5
	min_sample_split	[2, 3, 4]	1	1	1
	min_sample_leaf	[1, 2, 3, 4]	2	4	4
RFR	n_estimators	[100, 200, 300]	200	200	100
	max_depth	[10, 20, 30]	10	10	10
	min_sample_split	[2, 5, 10]	1	1	1
	min_sample_leaf	[1, 2, 3, 4]	2	2	2
Laguna de Ubaque					
Modelo	**Hiperparametros**	**Valores probados**	**Mejor Valor (Nitratos)**	**Mejor valor (Fosfatos)**	**Mejor valor (Turbidez)**
SVR	C	[0.1, 1, 10, 100]	0,1	0,1	100
	epsilon	[0.01, 0.1, 1]	1	0,1	0,1
	kernel	['rbf', 'linear', 'poly']	linear	linear	poly
GBR	n_estimators	[100, 200, 300]	100	200	200
	learning_rate	[0.01, 0.1, 0.2]	0,2	0,1	0,1
	max_depth	[3, 4, 5]	3	3	4
	min_sample_split	[2, 3, 4]	2	1	1
	min_sample_leaf	[1, 2, 3, 4]	2	2	2
RFR	n_estimators	[100, 200, 300]	100	200	100
	max_depth	[10, 20, 30]	10	10	10
	min_sample_split	[2, 5, 10]	1	1	1
	min_sample_leaf	[1, 2, 3, 4]	2	2	2

Fuente: Elaboración Propia

Estos resultados evidencian que la configuración óptima de los hiperparámetros varía en función del parámetro de calidad del agua analizado y a la zona de estudio, lo que destaca la importancia de un ajuste específico para cada modelo y variable de interés. En particular, se observa que la predicción de turbidez requiere configuraciones diferentes en comparación con nitratos y fosfatos, especialmente en términos del kernel en SVR y la cantidad de estimadores en GBR. Esto resalta la relevancia de seleccionar adecuadamente los hiperparámetros para mejorar la precisión de los modelos y optimizar su capacidad predictiva en el monitoreo de la calidad del agua.

Adicionalmente se evidencia que los cambios encontrados en la calidad de agua obligan a los modelos de aprendizaje automático a tomar otros valores en los hiperparametros, con lo cual se hace necesario cada vez que se genere nueva información de diferentes cuerpos de agua lenticos estimar los mejores hiperparametros y entrenar con puntos de referencia.

Para evaluar el desempeño de los modelos se evaluó el R2, MAE y RMSE (Tabla 5-3) para los tres parámetros de calidad de agua en cada zona de estudio encontrando que, en la predicción de turbidez, el modelo GBR obtuvo el mejor desempeño con un R2 de 0.9 y 0.85 para la Laguna La Herrera y Ubaque respectivamente, un RMSE de 30.34 y un MAE de 4.29, lo que indica una alta precisión en sus predicciones. En contraste, el SVR presentó un desempeño considerablemente más bajo, con un R2 de 0.47 y 0.7 para la Laguna La Herrera y Ubaque, un RMSE de 350.98, 0.0152 y un MAE de 16.05 y 0.79, lo que sugiere que sus predicciones tienen una mayor desviación respecto a los valores reales. El RFR, por su parte, mostró un desempeño intermedio, con un R2 de 0.83 y 0.68 pero menos eficiente que el GBR.

Tabla 5-3 Métricas de rendimiento de los modelos de aprendizaje computacional

Laguna La Herrera									
Parámetro	**Turbidez**			**Nitratos**			**Fosfatos**		
Modelo	**R2**	**RMSE**	**MAE**	**R2**	**RMSE**	**MAE**	**R2**	**RMSE**	**MAE**
SVR	0,47	350,98	16,05	0,41	18,5	3,4	-0,02	2,14	1,1
GBR	0,9	30,34	4,29	0,85	1,25	0,97	0,87	0,0083	0,079
RFR	0,83	80,87	8,52	0,81	2,32	1,25	0,79	0,017	0,1
Laguna de Ubaque									
Parámetro	**Turbidez**			**Nitratos**			**Fosfatos**		
Modelo	**R2**	**RMSE**	**MAE**	**R2**	**RMSE**	**MAE**	**R2**	**RMSE**	**MAE**
SVR	0,7	0,0152	0,0785	0,79	0,086	0,19	0,68	0,14	0,29
GBR	0,85	0,0023	0,043	0,85	0,011	0,067	0,89	0,043	0,16
RFR	0,68	0,016	0,093	0,91	0,0055	0,048	0,81	0,027	0,13

Fuente: Elaboración Propia

Para ambas zonas de estudio el modelo de aprendizaje automático que mejores métricas de desempeño tiene es el GBR, con R2 que oscilan entre 0.85 a 0.9 en los parámetros de calidad de agua analizado, por lo que se infiere que la capacidad predictiva de este modelo es la mejor independiente del estado de contaminación del cuerpo de agua. También el modelo GBR obtuvo los errores más bajos (RMSE y MAE). El RFR se posiciona como una alternativa viable, aunque con unas métricas de desempeño ligeramente inferior, mientras que el SVR mostró un desempeño inconsistente, con errores elevados y baja capacidad predictiva, especialmente en la estimación de fosfatos.

A partir de los modelos entrenados y validados se generó la estimación espacial de cada parámetro de calidad de agua en la Laguna La Herrera (Figura 5-10).

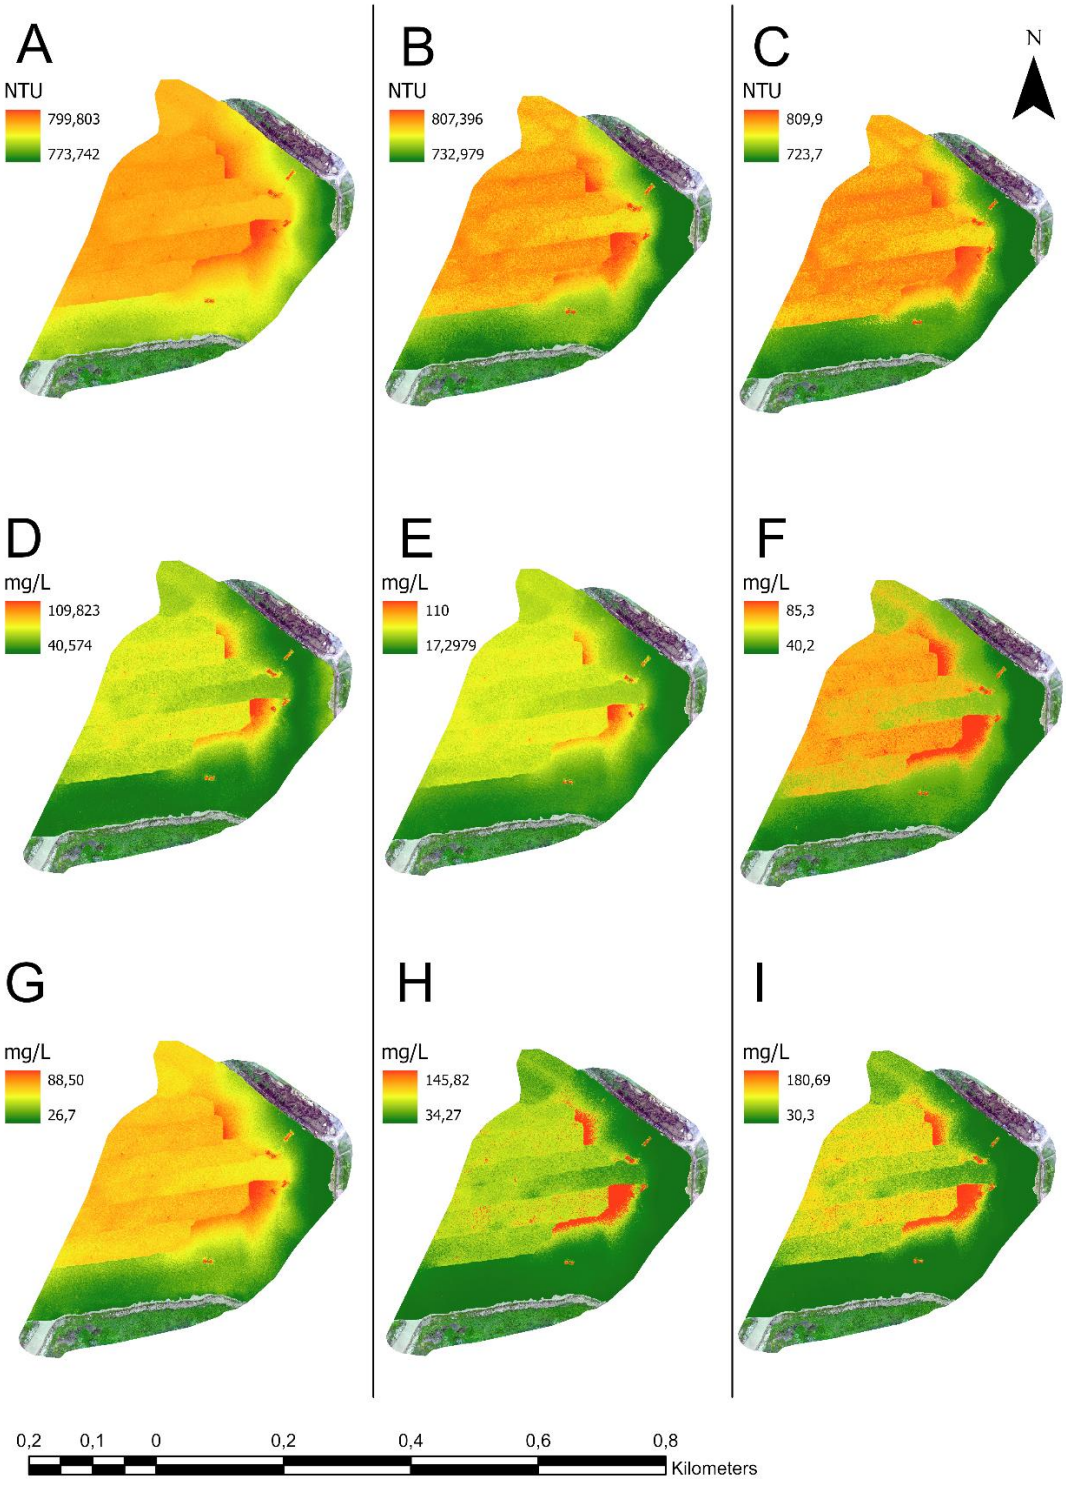
A
NTU
799,803
773,742
B
NTU
807,396
732,979
C
NTU
809,9
723,7
N
D
mg/L
109,823
40,574
E
mg/L
110
17,2979
F
mg/L
85,3
40,2
G
mg/L
88,50
26,7
H
mg/L
145,82
34,27
I
mg/L
180,69
30,3
0,2 0,1 0 0,2 0,4 0,6 0,8
Kilometers

Figura 5-6 Espacialización de los parámetros de calidad de agua en la Laguna la Herrera. (A. Turbidez con SVR, Turbidez con RFR, C. Turbidez con GBR, D. Nitratos con SVR, E. Nitratos con RFR, F. Nitratos con GBR, G. Fosfatos con SVR, H. Fosfatos con RFR, I. Fosfatos con GBR) EPSG: 9377

Fuente: Elaboración Propia

El análisis de la espacialización de los parámetros de calidad del agua revela que las concentraciones de turbidez, nitratos y fosfatos obtenidas a partir de los modelos RFR y GBR presentan similitudes notables. Esto es coherente con los resultados obtenidos en las métricas de desempeño reportadas en la Tabla 5-2, donde estos modelos demostraron el mejor ajuste a los datos.

En la distribución espacial de las concentraciones de los parámetros evaluados, se observa que la zona central de la laguna presenta los valores más elevados de turbidez, nitratos y fosfatos. Esta concentración elevada se explica por los procesos de adecuación que se estaban llevando a cabo en el momento de la toma de datos, los cuales incluían la remoción de material vegetal y sedimentos en esta área. Dichos trabajos provocaron una resuspensión de sólidos en la columna de agua, lo que resultó en un aumento significativo en la concentración de los parámetros analizados.

Es importante destacar que esta dinámica no es fácilmente perceptible en la ortoimagen, ya que a simple vista no es posible diferenciar con claridad las zonas en las que se realizaron estas adecuaciones. Sin embargo, mediante las estimaciones espaciales generadas por los modelos de aprendizaje automático, se logra evidenciar de manera precisa estos patrones de variabilidad en la calidad del agua. Esto denota la importancia de la aplicación de algoritmos de aprendizaje computacional, ya que permiten detectar y analizar cambios en la calidad del agua que no pueden ser identificados únicamente a partir de imágenes capturadas por UAS o mediante mediciones puntuales obtenidas en campo.

El análisis de la Laguna de Ubaque (Figura 5-11) revela que la estimación espacial de los parámetros de calidad del agua mediante el algoritmo SVR fue deficiente, ya que generó valores fuera del rango matemático de las concentraciones medidas en campo. Este comportamiento fue evidenciado en la turbidez y los nitratos, donde el modelo llegó a

predecir valores negativos, lo que es físicamente incorrecto y evidencia una inadecuada capacidad de generalización de este algoritmo para este caso específico.

Por otro lado, los modelos RFR y GRB mostraron estimaciones más coherentes y similares entre sí para los tres parámetros de calidad del agua analizados. Esto se debe a que las métricas de rendimiento de estos dos algoritmos arrojaron valores comparables, indicando que ambos tienen una capacidad predictiva similar en este contexto.

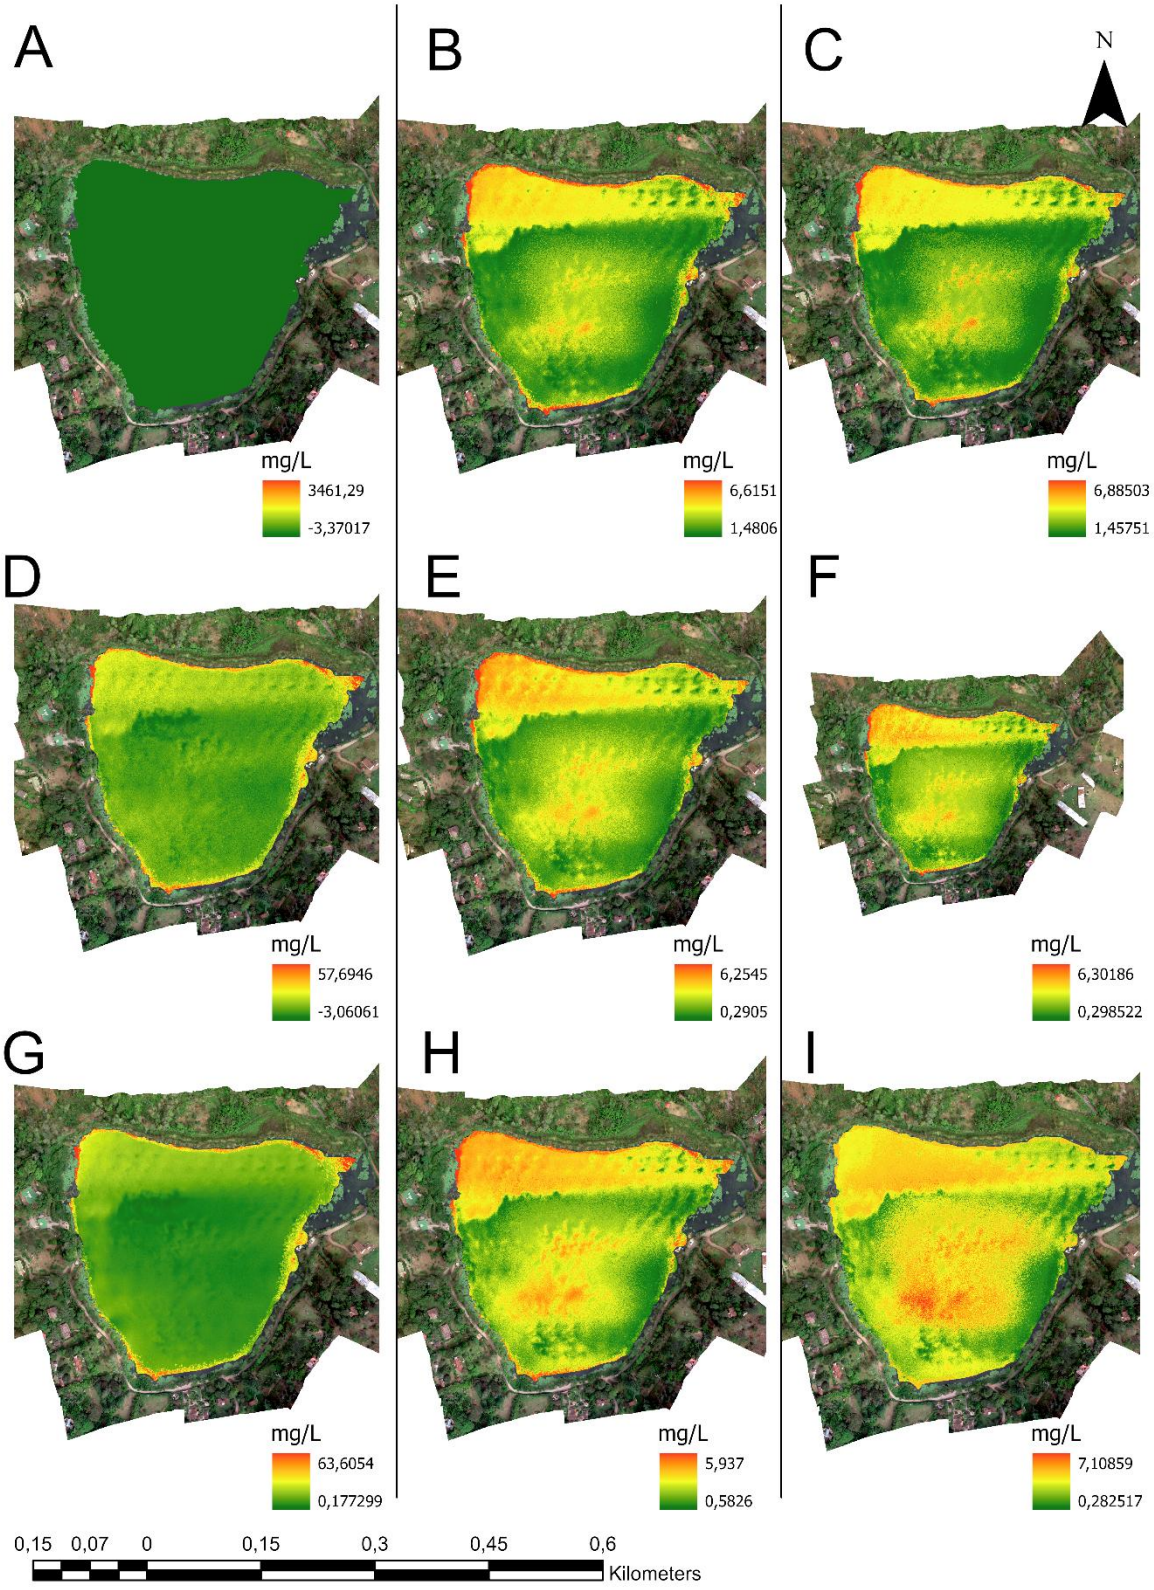
A
mg/L
3461,29
-3,37017
B
mg/L
6,6151
1,4806
C
N
mg/L
6,88503
1,45751
D
mg/L
57,6946
-3,06061
E
mg/L
6,2545
0,2905
F
mg/L
6,30186
0,298522
G
mg/L
63,6054
0,177299
H
mg/L
5,937
0,5826
I
mg/L
7,10859
0,282517
0,15 0,07 0 0,15 0,3 0,45 0,6
Kilometers

Figura 5-7 Espacialización de los parámetros de calidad de agua en la Laguna Ubaque. (A. Fosfatos con SVR, Fosfatos con RFR, C. Fosfatos con GBR, D. Nitratos con SVR, E. Nitratos con RFR, F. Nitratos con GBR, G. Turbidez con SVR, H. Turbidez con RFR, I. Turbidez con GBR) EPSG: 9377

Fuente: Elaboración Propia

A diferencia de lo observado en la Laguna La Herrera, donde las concentraciones más altas de turbidez, nitratos y fosfatos se registraron en la zona central debido a actividades de adecuación, en la Laguna de Ubaque se encontró un patrón opuesto. Aquí, las mayores concentraciones de los tres parámetros se ubicaron en los bordes de la laguna, lo que puede atribuirse a la menor profundidad en estas áreas y a la influencia de las actividades turísticas. La presencia constante de visitantes genera una resuspensión de sólidos en la columna de agua, alterando la calidad del agua y elevando los niveles de turbidez, nitratos y fosfatos.

Este hallazgo resalta la importancia de considerar la dinámica de uso y las características físicas de cada cuerpo de agua al interpretar los resultados de modelos predictivos. Además, genera la necesidad de seleccionar algoritmos adecuados para la estimación de parámetros ambientales, dado que algunos, como el SVR, pueden no ser aptos para ciertos entornos o variables, generando estimaciones erróneas que pueden llevar a interpretaciones incorrectas de estos parámetros.

5.4 Validación de los modelos generados

A partir de las estimaciones generadas para los tres parámetros de calidad de agua, se generó la validación de los modelos tomando 5 puntos aleatorios en cada área de estudio, reportando los valores del RMSE para cada parámetro, algoritmo y área de estudio (Tabla 5-3).

Figura 5-8 RMSe encontrado en las estimaciones espaciales de los parámetros de calidad de agua.

Área de estudio	Modelo	Turbidez	Nitratos	Fosfatos
Laguna la herrera	SVR	390,4	36,5	10,5
	RFR	120,9	6,8	1,3
	GBR	45,7	3,8	0,39
Laguna Ubaque	SVR	20,48	18,5	15,47
	RFR	3,4	1,47	2,69
	GBR	1,4	0,89	0,74

Fuente: Elaboración Propia

El análisis de RMSE obtenidos en la estimación de los parámetros de calidad del agua revela que el modelo GBR presentó los valores más bajos, seguido de cerca por el RFR. Esto indica que estos dos algoritmos tienen un mejor desempeño en la predicción de la turbidez, los nitratos y los fosfatos en comparación con el SVR, que obtuvo los errores más altos.

En particular, los valores de error para el SVR superan el 50% del rango de medición de los parámetros analizados, lo que indica que este modelo no es adecuado para la estimación de la calidad del agua en este contexto, ya que su alto margen de error compromete la precisión y confiabilidad de los resultados. Por otro lado, el RFR mostró un error del 15%, mientras que el GBR presentó un error aún menor, de aproximadamente 10%, lo que lo convierte en la mejor opción entre los modelos evaluados.

Estos resultados sugieren que, al utilizar el sensor RedEdge Micasense P en combinación con el algoritmo GBR, las estimaciones de calidad del agua pueden presentar una sobreestimación o subestimación de aproximadamente un 10% en cada píxel generado a partir de los índices espectrales. Sin embargo, este margen de error sigue siendo aceptable en términos de modelado ambiental, ya que permite obtener una representación confiable de la distribución espacial de los parámetros de calidad del agua con una desviación relativamente baja respecto a los valores medidos en campo, lo cual puede reducir costos de muestreo y tiempos en obtener resultados confiables útiles para la toma de decisiones en el manejo de cuerpos lenticos de agua.

Finalmente se realizó la validación comparando los valores encontrados en el laboratorio para cada punto de muestreo con los generados por el ráster basado en el algoritmo GBR cuyo desempeño fue el mejor según lo mostrado en la tabla 5-2 (Figura 5-9).

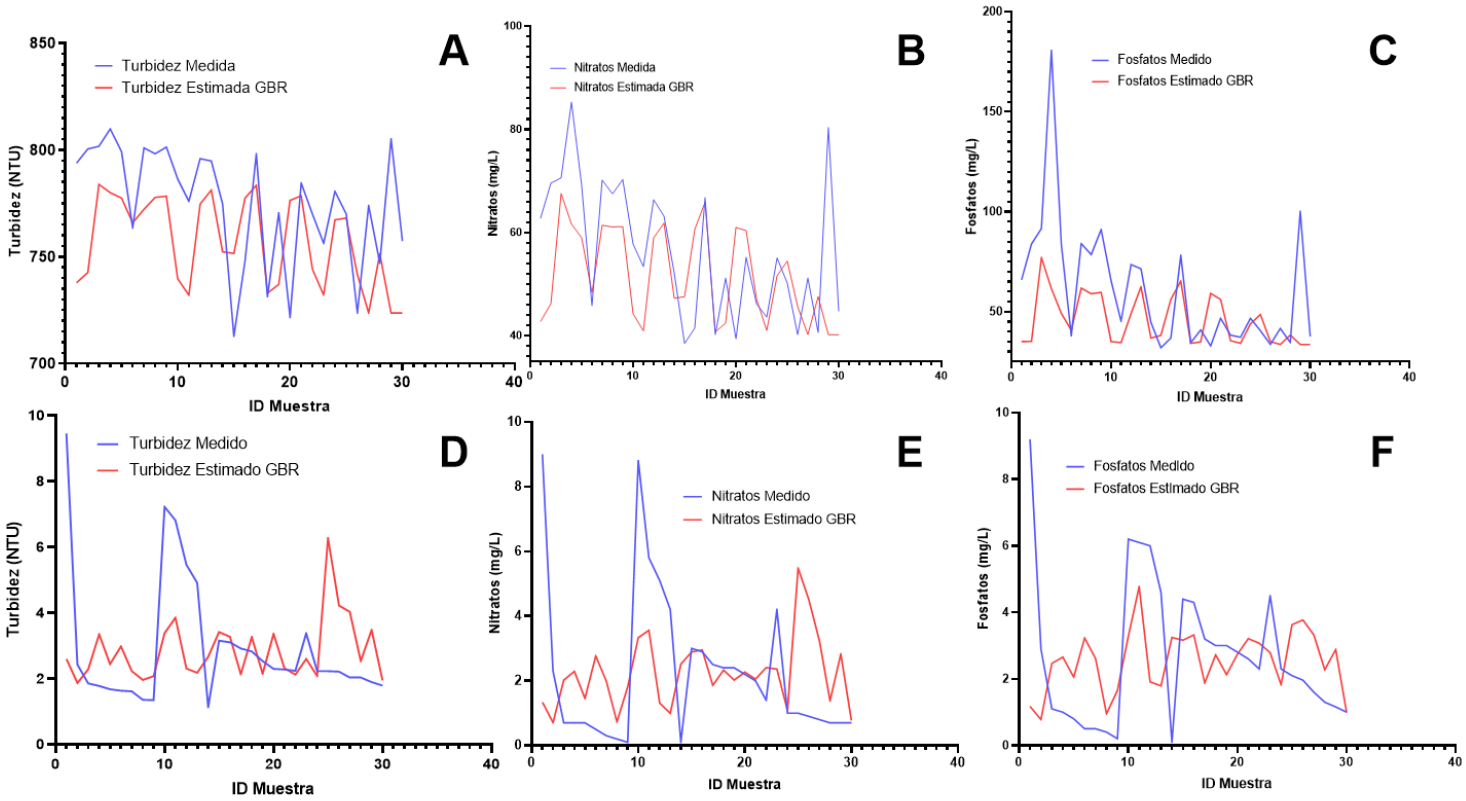

Figura 5-9 Validación por punto de muestreo para los parámetros de calidad de agua estimados con el algoritmo GBR (A. Turbidez Laguna La Herrera, B. Nitratos Laguna La Herrera, C. Fosfatos Laguna La Herrera, D. Turbidez Laguna Ubaque, E. Nitratos Laguna Ubaque, F. Fosfatos Laguna Ubaque).

Fuente: Elaboración Propia

De esta grafica de validación se puede evidenciar que el algoritmo GBR difiere en algunos puntos de muestreo con respecto al valor estimado en la superficie, ya que si bien tuvo las mejores métricas de rendimiento y de validación, existen puntos que por el efecto especular del agua, tienen reflectancias altas, por lo que aumenta el valor de las concentraciones estimadas con el modelo de aprendizaje automático, sin embargo las

tendencias y el rango de valores bajo el cual el modelo opera es óptimo para dar valores confiables sobre la calidad del agua.

En este sentido, el uso de modelos de aprendizaje computacional bien ajustados, como GBR y RFR, junto con datos espectrales obtenidos por sensores remotos, demuestra ser una estrategia eficiente para la evaluación y monitoreo de la calidad del agua en ecosistemas acuáticos, sin embargo, es necesario reconocer que no es viable realizar modelos conjuntos para estimar calidad del agua de forma general, ya que fue necesario entrenar dos modelos diferentes para estimar calidad del agua en zonas sin afectación antrópica y con alta afectación debido a las fuertes diferencias en la reflectancia saliente de las imágenes que impide generalizar los modelos de forma adecuada, por lo tanto para otros cuerpos de agua es necesario entrenar los modelos con datos de referencia tomados en campo para así estimar con más exactitud los parámetros de calidad de agua.

6. Discusión

Las respuestas espectrales obtenidas y representadas en la Figura 5-5 muestran un comportamiento similar al reportado en el estudio de Cui et al. (2022). En dicho estudio, se evidenció que la reflectancia del agua en cuerpos lénticos, captada mediante sensores remotos acoplados a un UAV, está estrechamente relacionada con la concentración de turbidez. Esta relación directa implica que, a medida que la turbidez del agua aumenta, se producen variaciones significativas en la firma espectral del cuerpo de agua, permitiendo su identificación y cuantificación a partir del análisis de datos espectrales.

Los cambios de coloración observados en las ortoimágenes generadas reflejan variaciones en la calidad del agua, en concordancia con lo reportado por De Keukelaere et al. (2023). En su investigación, se establece que las diferencias en la coloración de los cuerpos de agua están estrechamente relacionadas con la turbidez y otros parámetros ópticamente activos, como los fosfatos y nitratos, los cuales afectan la forma en que la luz es absorbida y dispersada en la columna de agua. Esta variabilidad en la respuesta espectral permite distinguir entre cuerpos de agua con diferentes niveles de contaminación, ya que los cambios en la composición química y en la cantidad de partículas en suspensión modifican significativamente la reflectancia en distintas bandas espectrales.

En particular, en la Figura 5-4, se observa que la Laguna de Ubaque presenta valores más bajos en los índices de vegetación en comparación con la Laguna La Herrera, lo que sugiere una menor presencia de materia orgánica flotante o sumergida en este cuerpo de agua. Asimismo, la Laguna de Ubaque exhibe valores más altos en los índices de agua, lo que indica una menor sedimentación en el sistema léntico. Esto implica una reducida acumulación de partículas en suspensión y, por ende, concentraciones más bajas de turbidez, nitratos y fosfatos. Estos hallazgos concuerdan con estudios previos realizados por Fung & Siu (2000) y Kafrawy (2017), quienes demostraron que una menor sedimentación en cuerpos de agua suele estar asociada con una mejor calidad del agua y una menor presencia de contaminantes.

El análisis de regresión PLS permitió identificar las variables espectrales con mayor influencia en la estimación de la turbidez, destacando el NDVI y NDWI como los predictores

más relevantes. Estos resultados difieren de los hallazgos de Robert et al. (2016), quien reportó que las bandas del infrarrojo cercano (NIR) y la roja eran las más influyentes en la predicción de la turbidez. Esta discrepancia podría atribuirse a diferencias en las condiciones ambientales, en los sensores utilizados o en las características específicas de los cuerpos de agua analizados.

El análisis de nitratos y fosfatos mediante PLS reveló que el NDWI y NDVI fueron las variables más influyentes en la estimación de estos parámetros, al igual que en el caso de la turbidez (Figura 5-5). Sin embargo, estos resultados contrastan con lo reportado por Li et al. (2017), donde los modelos generados para la estimación espacial de nitratos y fosfatos se fundamentaron en las bandas roja, verde e infrarroja, mientras que los índices de agua y vegetación no fueron considerados (Tabla 6-1). Esto sugiere que las variables predictoras más relevantes pueden variar dependiendo del sensor remoto utilizado y de las condiciones específicas del cuerpo de agua analizado. Para el presente estudio, fue fundamental el uso del NDWI y NDVI, ya que los modelos de aprendizaje computacional desarrollados con SVR, FRF y GBR los incluyeron como variables predictoras, obteniendo así las métricas presentadas en la Tabla 5-2.

Tabla 6-1 Variables más importantes encontradas en el estudio con respecto a las referenciadas en la literatura

Parámetro	Variables más importantes (Estudio)	Variables más importantes (Referencia)	Cita
Turbidez	NDWI - NDVI	NIR - RED	Tan et al., 2015 ; Robert et al.,(2016)
Nitratos	NDWI - NDVI	NDVI	De Keukelaere et al., 2023 ; Li et al., (2017)
Fosfatos	NDWI - NDVI	NDVI	Cui et al., 2022

Fuente: Elaboración Propia

Los coeficientes de correlación máximos obtenidos para los parámetros de calidad del agua, representados en la Tabla 6-2, evidencian una alta asociación entre las concentraciones predichas de turbidez y nitratos y los valores obtenidos en laboratorio para

los modelos RFR y GBR. Estos resultados coinciden con lo reportado por Cui et al. (2022) y Robert et al. (2016), quienes encontraron correlaciones significativas entre las variables espectrales y los parámetros de calidad del agua utilizando tanto técnicas de regresión tradicional como métodos de aprendizaje computacional.

Estos hallazgos resaltan la importancia de la selección de variables espectrales óptimas para cada sensor y cuerpo de agua analizado, lo que permite mejorar la precisión de los modelos predictivos y facilita el monitoreo ambiental mediante técnicas de teledetección y aprendizaje automático.

Tabla 6-2 Comparación de R2 obtenidos en el estudio con los encontrados en la literatura

Parámetro	R2 máximo obtenido	R2 Referencias	Cita
Turbidez	0,87 (GBR)	0,79	Tan et al., 2015
Nitratos	0,85 (GBR)	0,85	De Keukelaere et al., 2023
Fosfatos	0,89 (GBR)	0,64	Cui et al., 2022

Fuente: Elaboración Propia

En cuanto a la selección del modelo, se evidenció que el algoritmo GBR fue el más preciso para predecir los tres parámetros de calidad del agua, obteniendo coeficientes de determinación (R^2) similares a los reportados por Cui et al. (2022), He et al. (2008) y Li et al. (2017), pero con modelos de aprendizaje computacional. Esto sugiere que los algoritmos empíricos y semiempíricos basados en modelos de transmisión de la radiación pueden ser equiparables a los modelos de aprendizaje computacional para la estimación espacial de parámetros de calidad del agua.

A partir de estos resultados, se propuso un flujo metodológico para la estimación de parámetros de calidad del agua utilizando el sensor Micasense RedEdge P y el UAS DJI Matrice 300 RTK. Este flujo metodológico permite la integración de técnicas de teledetección con modelos de aprendizaje computacional, facilitando la generación de

mapas de calidad del agua con alta precisión y confiabilidad, contribuyendo así a la gestión sostenible de los recursos hídricos.

6.1 Metodología para la estimación de parámetros de calidad de agua a partir de imágenes UAS y aprendizaje computacional

- **Parámetros de vuelo**

Para lograr una correcta ortorectificación de las imágenes y evitar huecos estereoscópicos en el vuelo de UAS, se debe garantizar que las imágenes de agua contengan una porción de suelo con el fin de que el ajuste el bloque se pueda realizar. Según anterior las alturas optimas de vuelos para cuerpos de agua lenticos van en función al área de estudio.

- 10 ha: 200 metros de altura (10cm GSD)
- 20 ha: 450 metros de altura (20cm GSD)
- 30 ha: 650 metros de altura (30cn GSD)

Si no es posible ajustar el bloque con el software de procesamiento ya que la extensión del cuerpo de agua impide la correcta ortorectificacion se deberán poner puntos de referencia manual en el cuerpo de agua para que el algoritmo los detecte y ajuste correctamente las imágenes.

Por otro lado, el vuelo definido en el UAS debe ser un **vuelo cartográfico** generando las respectivas líneas de vuelo en el software a las alturas definidas para el área de estudio.

- **Definición del área de estudio**

La definición del área de estudio va en función al espejo de agua del cuerpo lentico que se quiere medir, por lo que se deben revisar insumos satelitales como los dispuestos por la USGS y en ALASKA FACILITY VERTEX para delimitar los cuerpos de agua y estimar correctamente las alturas de vuelo. Posteriormente se debe trazar un polígono de referencia para ingresarlo al software DJI Pilot y generar las líneas de vuelo.

- **Trabajo en campo**
  - **Toma de datos con UAS**

Para la toma de datos con el UAS se debe tener en cuenta la lista de chequeo garantizando que todos los componentes del sistema UAS están completos. (Tabla 6-3)

Tabla 6-3 Lista de chequeo elementos para la toma de datos UAS

Elemento	Cantidad
UAS DJI Matrice 300 RTK	1
Elices	4
Baterías UAS	4
Tren de aterrizaje	2
Control DJI	1
DLS	1
Sensor RedEdge Micasense P	1
Tornillos ensamble Sensor - UAS	8
Skyport	1
Cable conexión UAS - Skyport	1
Antena DJI RTK2	1
Trípode	1
Baterías antena	2
Pista de aterrizaje	1
Estacas	4

Fuente: Elaboración Propia

Garantizando de que todos los elementos estén completos, se procederá a realizar el montaje del sistema Sensor – UAS, como se evidencia en la Figura 4-2. Posteriormente se procederá a realizar la calibración del IMU, brújula, y configuración de los parámetros de vuelo (Tabla 6-4).

Tabla 6-4 Actividades a realizar previa captura de la información

Actividad	Tiempo (min)
Calibración IMU	5
Calibración brújula	5
Configuración parámetros de vuelo software DJI	10
Configuración parámetros de vuelo software Micasense	10
Verificación de alertas del UAS	2

Fuente: Elaboración Propia

Estas actividades aproximadamente toman 30 minutos, por lo que se debe tener la disponibilidad de tiempo para realizar la actividad.

Durante el vuelo es necesario seguir las especificaciones dadas por la RAC 100, evaluando alturas de vuelo máximas, zonas de riesgo y exclusión entre otras, también es necesario que junto con el piloto UAS este un observador que alerte al piloto frente a cualquier obstáculo detectado en las líneas de vuelo.

Posterior al vuelo se debe revisar que las imágenes hayan sido capturadas de forma adecuada, para lo cual se extraerá la memoria de la cámara y se revisara en un computador personal que existan los registros de las imágenes del vuelo hecho.

Finalmente se procederá al desmonte del sistema Sensor – UAS volviendo a revisar la lista de chequeo de la Tabla 6-3.

- **Toma de datos en campo**

La toma de datos en campo requiere 2 acompañantes con la finalidad de optimizar las labores y evitar de que el tiempo entre el vuelo y la captura de información sea de más 2 horas ya que la asociación entre la reflectancia de las imágenes y los parámetros de calidad del agua depende de los tiempos de retención en el cuerpo de agua. Para la toma de datos se necesita lo especificado en la Tabla 6-4.

Tabla 6-5 Elementos necesarios para el muestro de calidad de agua

Elemento	Cantidad
Nevera	1
Botellas ámbar 250 mL	Depende de la cantidad de muestras
Antena GNSS	1
Batería antena GNSS	1
Rótulos	Depende de la cantidad de muestras
Bote o Lancha	1

Fuente: Elaboración Propia

Previo al muestreo de agua, se deben rotular las botellas identificando el número del punto muestreado. Ya en el bote o lancha se deben definir los puntos de muestreo, tomando superficialmente el agua del cuerpo de agua y tomando el punto con ayuda de la antena GNSS conecta al dispositivo móvil utilizando un software como AVENZA que facilite la adquisición de los datos. Por último, se deben disponer las botellas en la nevera y analizar las muestras no dejando pasar más de 24 horas entre el muestreo y el análisis en laboratorio.

- **Ortorectificación de imágenes UAS**

La ortorectificación de las imágenes se debe realizar siguiendo el proceso metodológico mostrado en el inciso 4.4.1, donde se utilizó el software Agisoft Metashape garantizando que todas las imágenes estén ajustadas antes de la generación del modelo digital de superficie y de ejecutar el algoritmo de ortorectificación.

- **Extracción de valores de reflectancia y cálculo de índices espectrales**

La extracción de los valores de reflectancia se debe realizar utilizando el kernel 3x3 mostrado en el inciso 4.6, así mismo las fórmulas para calcular los índices espectrales NDVI e NDWI se presentan en el inciso 4.3. Finalmente se debe construir un Feature Layer con los puntos de muestreo espacializados y asociados con los valores obtenidos de los parámetros de calidad de agua incluyendo los valores de reflectancia de cada banda y los

valores de los índices espectrales calculados construyendo el modelo de datos mostrado en la tabla 6-6.

Tabla 6-6 Esquema de datos para consolidar los resultados del procesamiento de la ortoimagen y los parámetros de calidad de agua

Atributo	Tipo de dato
ID	Long
Blue	Long
Green	Long
Red	Long
Red_Edge	Long
NIR	Long
NDWI	Double
NDVI	Double
Nitratos	Double
Fosfatos	Double
Turbidez	Double

Fuente: Elaboración Propia

- **Ejecución de modelos de aprendizaje computacional**

La ejecución de los modelos de aprendizaje computacional puede ser llevado a cabo haciendo uso del set de datos con el que se realizó este estudio o uno independiente. Para lo cual se deben seguir los siguientes pasos.

- Descargar el proyecto dispuesto en GitHub (Anexo 1)
- Enrutar el set de datos que viene por defecto o el construido según el modelo de datos de la tabla 6-6.

Figura 6-1 Variable a remplazar por el set de datos construido

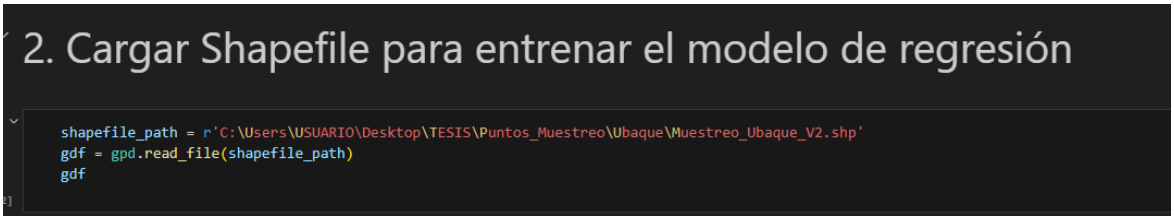

Fuente: Elaboración Propia

- Ejecutar el notebook hasta el numeral 5.1 “Validación de los modelos” y evaluar las métricas de rendimiento arrojadas para cada algoritmo.
- En caso de que las métricas no sean las adecuadas se pueden ajustar los hiperparametros o evaluar la gráfica del numeral 4.1 para escoger las mejores variables de estudio.
- En la sección 6. Enrutar las bandas por separado e índices espectrales a utilizar, debe corresponder con las mismas variables predictoras con las que se entrenaron los modelos

Figura 6-2 Sección del notebook para enrutar las bandas de la ortoimagen generada y los índices espectrales

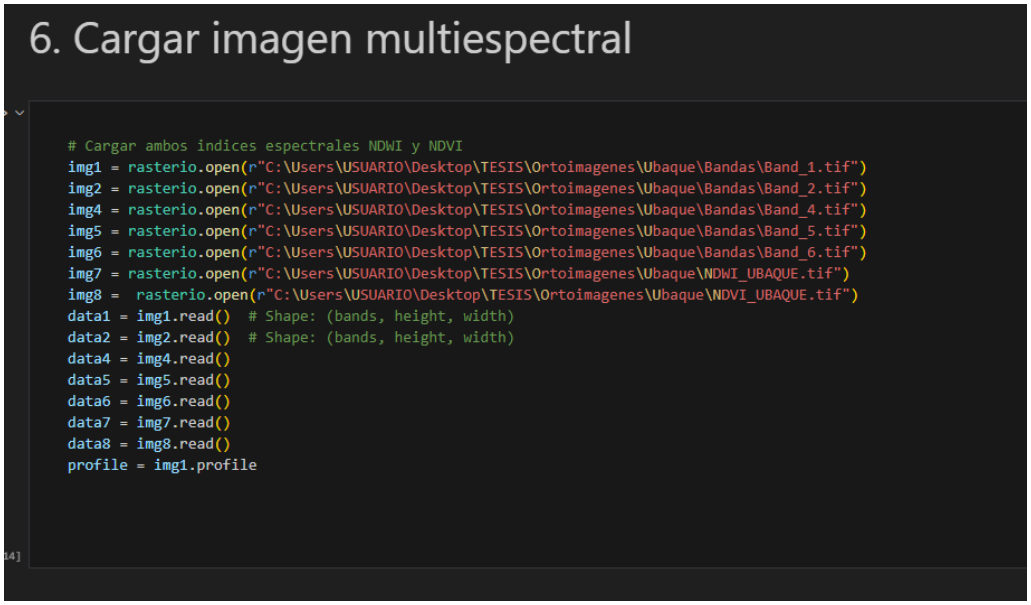

Fuente: Elaboración Propia

- Seguir la ejecución del notebook hasta la sección 8, cambiando las rutas de salida de los parámetros de calidad de agua que se quieren estimar.

Figura 6-3 Sección del notebook para enturar la salida de las representaciones espaciales de los parametros de calidad de agua.

Fuente: Elaboración Propia

- Visualizar los resultados en un software GIS e interpretar los resultados.

- **Diagrama metodológico.**

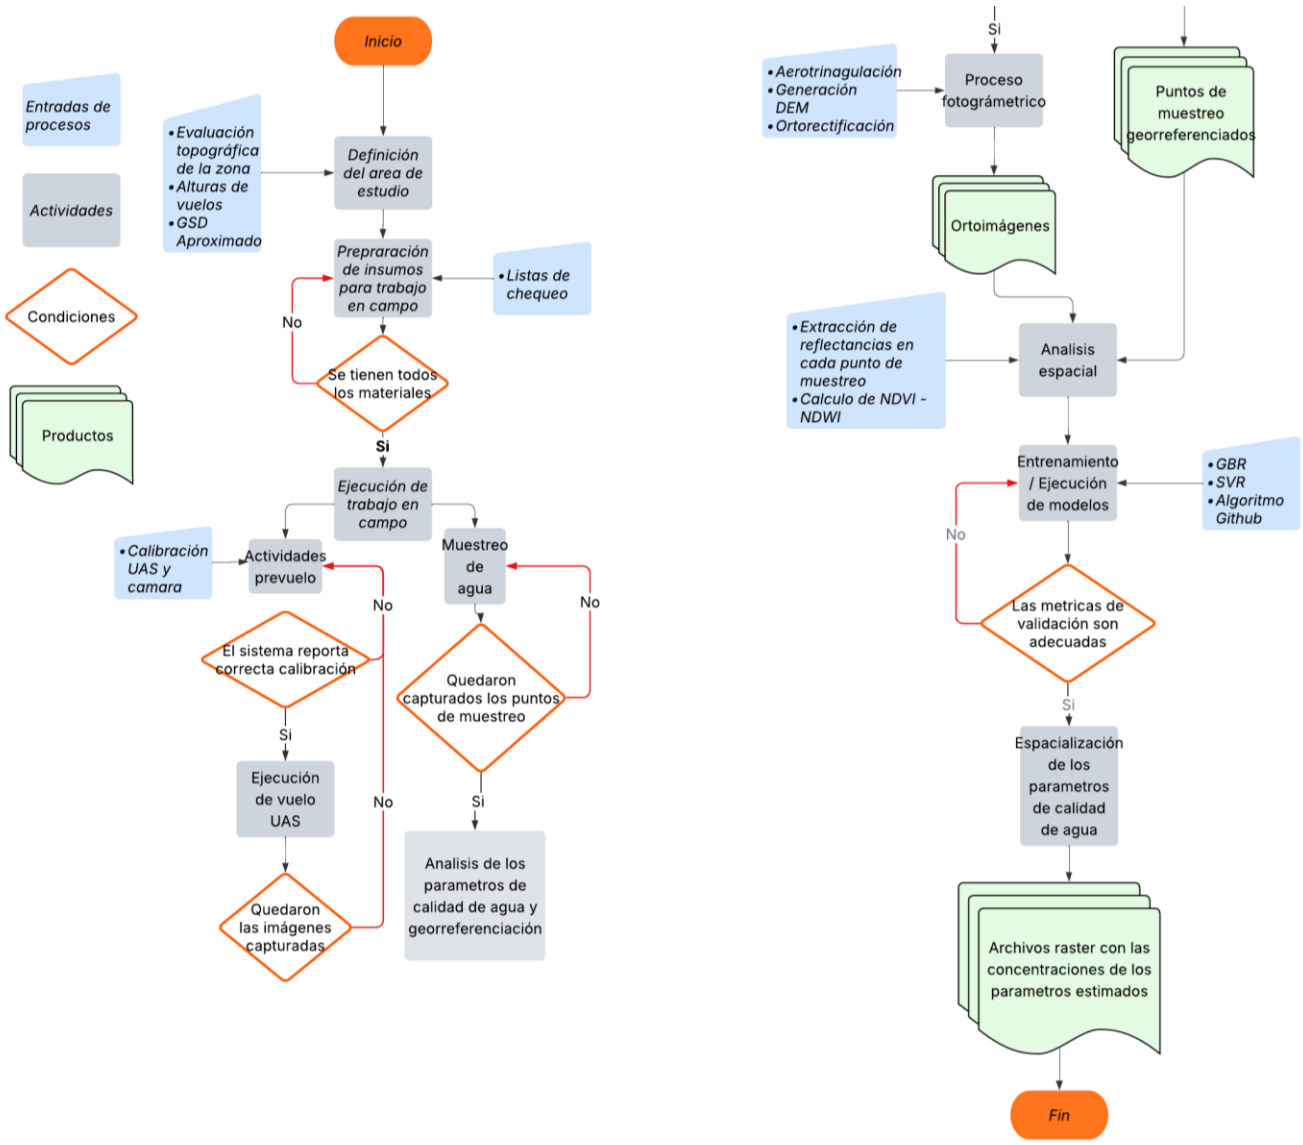

Figura 6-4 Diagrama metodológico para la estimación espacial de parámetros de calidad de agua con aprendizaje automático

7. Conclusiones

a. Conclusiones

El presente estudio evaluó el potencial del uso de imágenes capturadas con UAS para la estimación de parámetros de calidad de agua, demostrando una asociación significativa entre los valores de reflectancia espectral y las condiciones fisicoquímicas del agua. Esta relación permitió la implementación de algoritmos de aprendizaje computacional para la predicción de parámetros clave, estableciendo una metodología robusta basada en técnicas de teledetección.

A partir de esta asociación, se desarrollaron modelos de aprendizaje computacional utilizando tres algoritmos principales: Support Vector Regression (SVR), Random Forest Regressor (RFR) y Gradient Boosting Regressor (GBR). El desempeño de estos modelos fue comparado con el objetivo de identificar el más eficiente en la estimación de turbidez, fosfatos y nitratos. Los resultados evidenciaron que el algoritmo GBR presentó el mejor rendimiento en términos de precisión y estabilidad, consolidándose como la opción más adecuada para la estimación de estos parámetros en sistemas lénticos.

Para evaluar la exactitud de las predicciones obtenidas, se compararon los valores estimados con los datos de referencia obtenidos en laboratorio, calculando el error cuadrático medio (RMSE) entre las imágenes procesadas y los valores reales de calidad del agua. Los resultados indicaron que los métodos de aprendizaje computacional presentan un nivel de precisión aceptable para la estimación espacial de turbidez, nitratos y fosfatos, lo que demuestra su viabilidad como herramientas de monitoreo ambiental en cuerpos de agua lénticos.

Estos resultados no solo confirman la utilidad de las imágenes obtenidas por UAS en la evaluación de la calidad del agua, sino que también sientan las bases para futuras investigaciones enfocadas en la estimación de otros parámetros relevantes para la gestión de recursos hídricos. En este sentido, se sugiere ampliar el análisis a indicadores como la demanda química de oxígeno (DQO), el pH, la conductividad eléctrica y la clorofila, con el

fin de fortalecer la capacidad de monitoreo remoto y permitir una toma de decisiones más rápida y precisa.

El uso de estas metodologías innovadoras en la teledetección y el aprendizaje automático tiene el potencial de mejorar significativamente la gestión de los ecosistemas acuáticos, asegurando la preservación de los servicios ecosistémicos que ofrecen los cuerpos de agua lénticos. A medida que avancen las investigaciones en este campo, será posible optimizar aún más los modelos predictivos y extender su aplicabilidad a diferentes contextos ambientales, facilitando la implementación de estrategias efectivas para la conservación y el manejo sostenible del recurso hídrico.

b. Recomendaciones

- Se sugiere para cada estudio de calidad de agua en cuerpos lenticos tomar muestras de referencia para evaluar el desempeño de los algoritmos y ajustaros en caso de ser necesario
- Para otros parámetros de calidad de agua diferentes a los analizados en el presente estudio es necesario realizar todo el flujo metodológico y evaluar otros índices espectrales en la literatura que pueden aportar a la estimación de los mismos
- El procesamiento fotogramétrico es fundamental para la estimación de los parámetros de calidad de agua por lo que se debe realizar con la mayor exactitud espacial posible.

A. Anexo: Código para la estimación de parámetros de calidad de agua.

https://github.com/neotracer1/WQ_ML

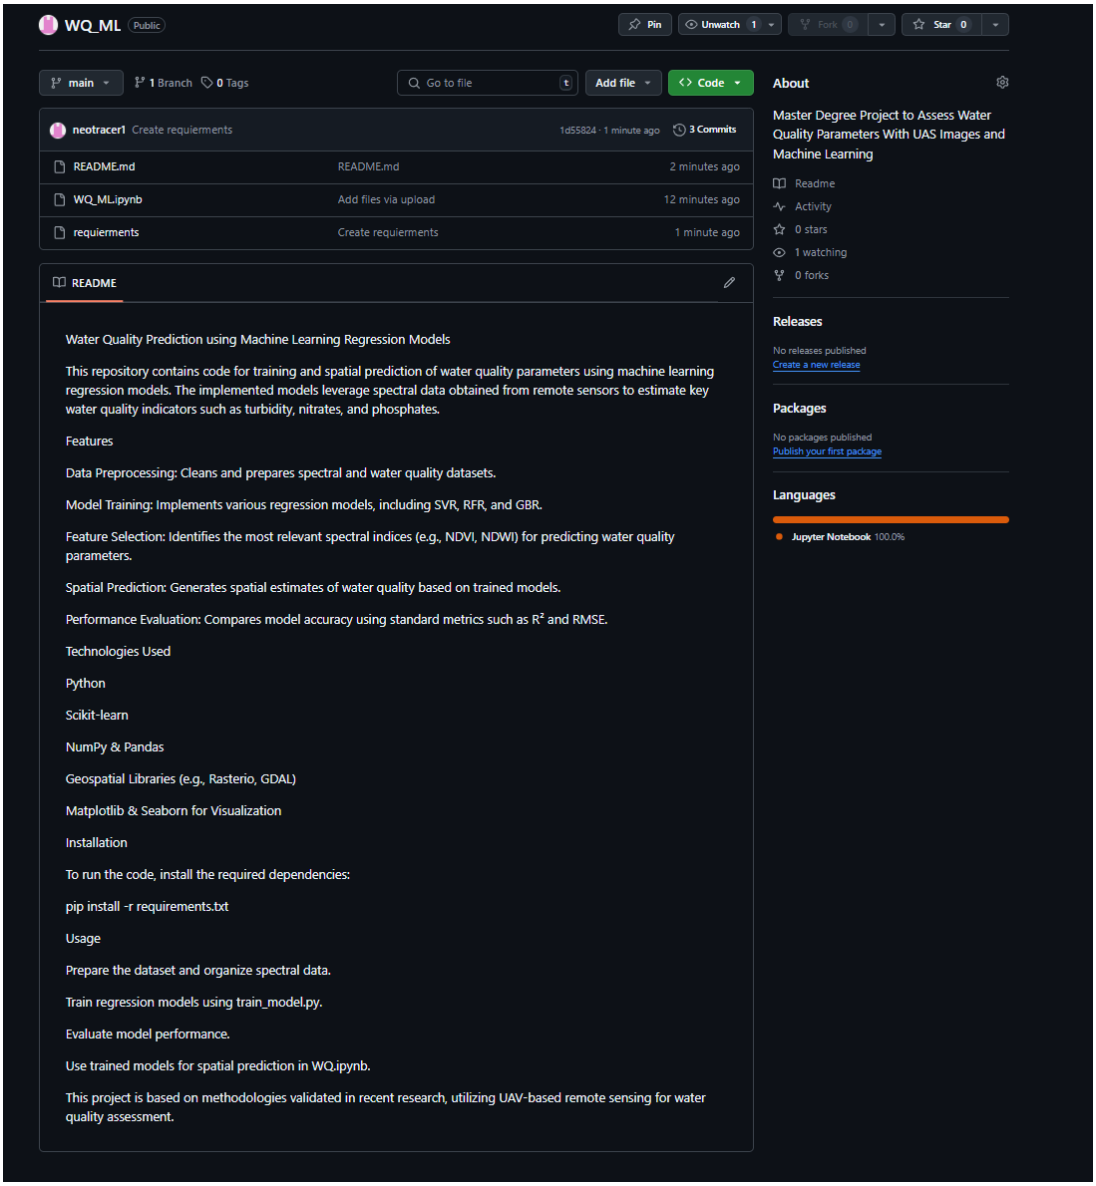

Bibliografía

Abella, J., & Martínez, M. (2013). CONTRIBUCIÓN DE UN AFLUENTE TRIBUTARIO A LA EUTROFIZACIÓN DEL LAGO DE TOTA (BOYACÁ, COLOMBIA) CONTRIBUTION OF A TRIBUTARY STREAM TO EUTROPHICATION OF LAKE TOTA (BOYACÁ, COLOMBIA) CONTRIBUIÇÃO DE AFLUENTES À EUTROFIZAÇÃO DO LAGO TOTA (BOYACÁ, COLÔMBIA). *Revista Colombiana de Química*, *41*(2), 243–262.

Bhateria, R., & Jain, D. (2016). Water quality assessment of lake water: a review. *Sustainable Water Resources Management*, *2*(2), 161–173. https://doi.org/10.1007/s40899-015-0014-7

Buiteveld, H., Hakvoort, J., & Donze, M. (1994). The optical properties of pure water. *Ocean Optics*, *XII*, 174–183.

Cao, S., Danielson, B., Clare, S., Koenig, S., Campos-Vargas, C., & Sanchez-Azofeifa, A. (2019). Radiometric calibration assessments for UAS-borne multispectral cameras: Laboratory and field protocols. *ISPRS Journal of Photogrammetry and Remote Sensing*, *149*, 132–145. https://doi.org/10.1016/j.isprsjprs.2019.01.016

Chen, B., Mu, X., Chen, P., Wang, B., Choi, J., Park, H., Xu, S., Wu, Y., & Yang, H. (2021). Machine learning-based inversion of water quality parameters in typical reach of the urban river by UAV multispectral data. *Ecological Indicators*, *133*. https://doi.org/10.1016/j.ecolind.2021.108434

Chen, J., Quan, W., Cui, T., & Song, Q. (2015). Estimation of total suspended matter concentration from MODIS data using a neural network model in the China eastern coastal zone. *Estuarine, Coastal and Shelf Science*, *155*, 104–113. https://doi.org/10.1016/j.ecss.2015.01.018

Conley, D. J., Paerl, H. W., Howarth, R. W., Boesch, D. F., Seitzinger, S. P., Havens, K. E., Lancelot, C., & Likens, G. E. (2009). Ecology - Controlling eutrophication: Nitrogen and phosphorus. In *Science* (Vol. 323, Issue 5917, pp. 1014–1015). https://doi.org/10.1126/science.1167755

Cui, M., Sun, Y., Huang, C., & Li, M. (2022). Water Turbidity Retrieval Based on UAV Hyperspectral Remote Sensing. *Water (Switzerland)*, *14*(1). https://doi.org/10.3390/w14010128

De Keukelaere, L., Moelans, R., Knaeps, E., Sterckx, S., Reusen, I., De Munck, D., Simis, S. G. H., Constantinescu, A. M., Scrieciu, A., Katsouras, G., Mertens, W., Hunter, P. D., Spyrakos, E., & Tyler, A. (2023). Airborne Drones for Water Quality Mapping in Inland, Transitional and Coastal Waters—MapEO Water Data Processing and Validation. *Remote Sensing*, *15*(5). https://doi.org/10.3390/rs15051345

Downing, J. A., Prairie, Y. T., Cole, J. J., Duarte, C. M., Tranvik, L. J., Striegl, R. G., Mcdowell, W. H., Kortelainen, P., Caraco, N. F., Melack, J. M., & Middelburg, J. J. (2006). The global abundance and size distribution of lakes, ponds, and impoundments. In *Limnol. Oceanogr* (Vol. 51, Issue 5). https://doi.org/https://doi.org/10.4319/lo.2006.51.5.2388

Elton, D. (2016). *Understanding the dielectric properties of water* (1st ed., Vol. 1). Stony Brook University.

Gao, Y., Gao, J., Yin, H., Liu, C., Xia, T., Wang, J., & Huang, Q. (2015a). Remote sensing estimation of the total phosphorus concentration in a large lake using band combinations and regional multivariate statistical modeling techniques. *Journal of Environmental Management*, *151*, 33–43. https://doi.org/10.1016/j.jenvman.2014.11.036

Gao, Y., Gao, J., Yin, H., Liu, C., Xia, T., Wang, J., & Huang, Q. (2015b). Remote sensing estimation of the total phosphorus concentration in a large lake using band combinations and regional multivariate statistical modeling techniques. *Journal of Environmental Management*, *151*, 33–43. https://doi.org/10.1016/j.jenvman.2014.11.036

Gitelson, A. A., Dall'Olmo, G., Moses, W., Rundquist, D. C., Barrow, T., Fisher, T. R., Gurlin, D., & Holz, J. (2008). A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: Validation. *Remote Sensing of Environment*, *112*(9), 3582–3593. https://doi.org/10.1016/j.rse.2008.04.015

Guevara, G., Lozano, P., Reinoso, G., & Villa, F. (2009). Horizontal and seasonal patterns of tropical zooplankton from the eutrophic Prado Reservoir (Colombia). *Limnologica*, *39*(2), 128–139. https://doi.org/10.1016/j.limno.2008.03.001

Hassanalian, M., & Abdelkefi, A. (2017). Classifications, applications, and design challenges of drones: A review. In *Progress in Aerospace Sciences* (Vol. 91, pp. 99–131). Elsevier Ltd. https://doi.org/10.1016/j.paerosci.2017.04.003

Khan, F., & Abid, A. (2005). Eutrophication: An Ecological Vision. In *The Botanical Review* (Vol. 71, Issue 4).

Li, Y., Zhang, Y., Shi, K., Zhu, G., Zhou, Y., Zhang, Y., & Guo, Y. (2017). Monitoring spatiotemporal variations in nutrients in a large drinking water reservoir and their relationships with hydrological and meteorological conditions based on Landsat 8

imagery. *Science of the Total Environment*, *599–600*, 1705–1717. https://doi.org/10.1016/j.scitotenv.2017.05.075

McFeeters, S. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, *17*(7), 1425–1432. https://doi.org/10.1080/01431169608948714

Micasense. (2021). *User Guide for MicaSense Sensors*. https://support.micasense.com/hc/article_attachments/360100291434/User_Guide_for_MicaSense_Sensors__2_.pdf

Niu, C., Tan, K., Jia, X., & Wang, X. (2021). Deep learning based regression for optically inactive inland water quality parameter estimation using airborne hyperspectral imagery. *Environmental Pollution*, *286*. https://doi.org/10.1016/j.envpol.2021.117534

Ouma, Y. O., Waga, J., Okech, M., Lavisa, O., & Mbuthia, D. (2018). Estimation of Reservoir Bio-Optical Water Quality Parameters Using Smartphone Sensor Apps and Landsat ETM+: Review and Comparative Experimental Results. *Journal of Sensors*, *2018*. https://doi.org/10.1155/2018/3490757

Robert, E., Grippa, M., Kergoat, L., Pinet, S., Gal, L., Cochonneau, G., & Martinez, J. M. (2016). Monitoring water turbidity and surface suspended sediment concentration of the Bagre Reservoir (Burkina Faso) using MODIS and field reflectance data. *International Journal of Applied Earth Observation and Geoinformation*, *52*, 243–251. https://doi.org/10.1016/j.jag.2016.06.016

Satterwhite, M. B., Mitchell, H., Hemmer, T., & Leckie, J. D. (2003). Field Spectral Signatures of Snow, Ice, and Water. *Algorithms and Technologies for Multiespectral and Ultraspectral Imagery* , *XI*. https://doi.org/https://doi.org/10.1117/12.488363

Shen, M., Wang, S., Li, Y., Tang, M., & Ma, Y. (2021). Pattern of turbidity change in the middle reaches of the yarlung zangbo river, southern tibetan plateau, from 2007 to 2017. *Remote Sensing*, *13*(2), 1–25. https://doi.org/10.3390/rs13020182

Sibanda, M., Mutanga, O., Chimonyo, V. G. P., Clulow, A. D., Shoko, C., Mazvimavi, D., Dube, T., & Mabhaudhi, T. (2021). Application of drone technologies in surface water resources monitoring and assessment: A systematic review of progress, challenges, and opportunities in the global south. In *Drones* (Vol. 5, Issue 3). MDPI. https://doi.org/10.3390/drones5030084

Thornton Robert H Kennedy A Dale Magatn, K. W., & Sauf, G. E. (1982). AMERICAN WATER RESOURCES ASSOCIATION. In *WATER RESOURCES BULLETIN* (Vol. 18, Issue 3).

Wang, Y., Xia, H., Fu, J., & Sheng, G. (2004). Water quality change in reservoirs of Shenzhen, China: Detection using LANDSAT/TM data. *Science of the Total Environment*, *328*(1–3), 195–206. https://doi.org/10.1016/j.scitotenv.2004.02.020

Wetzel, R. (2001). Limnology Lake and River Ecosystems Third Edition. In *Academic Press* (Vol. 1).

Xiao, Y., Guo, Y., Yin, G., Zhang, X., Shi, Y., Hao, F., & Fu, Y. (2022). UAV Multispectral Image-Based Urban River Water Quality Monitoring Using Stacked Ensemble Machine Learning Algorithms—A Case Study of the Zhanghe River, China. *Remote Sensing*, *14*(14). https://doi.org/10.3390/rs14143272

Yang, H., Kong, J., Hu, H., Du, Y., Gao, M., & Chen, F. (2022). A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges. *Remote Sensing*, *14*(8). https://doi.org/10.3390/rs14081770