

Proyecto Paraná 2023

Víctor Gauto
GISTAQ (UTN-FRRe), IIDTHH
(UNNE, CONICET), Instituto
Gulich (UNC, CONAE)
victor.gauto@ca.frre.utn.edu.ar

Enid Utgés
GISTAQ (UTN-FRRe)

Daniela Tenev
GISTAQ (UTN-FRRe)

Mauricio Acosta
GISTAQ (UTN-FRRe)

Vera Geneyer
GISTAQ (UTN-FRRe)

Víctor Gómez
GISTAQ (UTN-FRRe)

Bruno Lossada Dusset
GISTAQ (UTN-FRRe)

Ariadna Seba
GISTAQ (UTN-FRRe)

Noelia Molo
GISTAQ (UTN-FRRe)

2025-12-04

Resumen La calidad del agua en la cuenca media del río Paraná está afectada principalmente por los sedimentos presentes. Estos son aportados mayoritariamente por el río Paraguay. Los sólidos en el agua no se distribuyen uniformemente entre orillas, generando gradientes de concentración. La costa de la provincia del Chaco muestra valores elevados de turbidez y la costa de Corrientes posee aguas más claras. Mediante muestreos, a lo largo de una transecta al río Paraná, y ensayos de laboratorio se obtienen las propiedades fisicoquímicas del agua. Utilizando los datos provistos por la plataforma espacial Sentinel-2 se accede a las características espectrales del agua. Aplicando técnicas de teledetección satelital se combinan estos datos para la generación de algoritmos que permitan estimar la distribución espacial de la calidad del agua en el río Paraná.

Este documento funciona como soporte del proyecto **Estimar indicadores de calidad de agua en la cuenca media del río Paraná para el desarrollo de un algoritmo mediante técnicas de teledetección satelital** (MSECRE0008604), desarrollado por el **Grupo de Investigación Sobre Temas Ambientales y Químicos** (GISTAQ) de la **Universidad Tecnológica Nacional Facultad Regional Resistencia** (UTN-FRRe).

El mencionado proyecto forma parte de las tareas de investigación del MS. Víctor Gauto, en el marco del **Doctorado en Geomática y Sistemas Espaciales**, dictado por el Instituto Gulich, en conjunto con la **Universidad Nacional de Córdoba** (UNC) y la **Comisión Nacional de Actividades Espaciales** (CONAE).

Asimismo, el doctorando cuenta con una beca CONICET radicada en el **Instituto de Investigaciones para el Desarrollo Territorial y del Hábitat Humano** (IIDTHH) de la **Universidad Nacional del Nordeste** (UNNE).

El presente sitio web contiene una introducción (1) al proyecto, seguido de la descripción del área de estudio (2). Hay un calendario de muestreos (4) y los resultados (5) se muestran por sitio y característica fisicoquímica, seguido de las firmas espectrales (6). En la discusión (7) se analizan trabajos referentes a turbidez, sólidos suspendidos y profundidad de disco de Secchi. Se indican el objetivo (8) general y específicos. Luego, se encuentran los algoritmos propuestos y, finalmente, la información de contacto (10).

La finalidad de este desarrollo es reunir en un único sitio web las características principales del proyecto de investigación para entender cómo registrar datos, visualizar resultados, evaluar algoritmos y que, además, sea utilizado como material de consulta general de la metodología.

1 Introducción

La preservación del agua es fundamental para el desarrollo humano y el monitoreo de la calidad del agua es una actividad importante para la preservación de los recursos. Para garantizar la disponibilidad de agua, de acuerdo con la Agenda 2030 para el Desarrollo Sostenible [1], es necesario realizar un estudio de la calidad de la misma. Las técnicas de teledetección satelital, aplicadas a la calidad de los cuerpos de agua, han ido incrementándose en los últimos años verificando la viabilidad de los sensores satelitales [2]. Dichas técnicas, que se pueden utilizar para desarrollar algoritmos que permiten estimar distintos parámetros fisicoquímicos del agua [3], [4], requieren datos espectrales obtenidos por sensores montados en plataformas satelitales. Sentinel-2 (S2) es una misión de observación de la Tierra, de la Agencia Espacial Europea (ESA), que consta de tres plataformas: S2A, S2B y S2C, lanzados al espacio en 2015, 2017 y 2024, respectivamente. El rango espectral del instrumento multispectral (MSI), el sensor principal, es de 440 a 2200 nm, con una resolución espacial de 10 m en bandas seleccionadas y 5 días de tiempo de revisita, según la región de interés. Las imágenes S2-MSI son de acceso libre y gratuito desde el Ecosistema Espacial de Datos de Copernicus. Debido a una baja incertidumbre radiométrica [5], los productos generados por S2-MSI son confiables [6] y se han utilizado para estimar el color del agua [7], la concentración de clorofila-a [8] y la materia orgánica disuelta coloreada (CDOM) [9].

Los ecosistemas de agua dulce son vulnerables a los cambios en la gestión de usos de la tierra, los impactos antrópicos [10] y la variabilidad climática [11]. Estos ecosistemas están presentes en lagos, arroyos, ríos y humedales. La aplicación de técnicas de teledetección a las aguas superficiales continentales presenta un desafío debido a la extensión relativamente menor y la alta complejidad espacial. Tradicionalmente, las aguas continentales se estudian mediante el desarrollo de algoritmos que correlacionan las propiedades espectrales con los parámetros fisicoquímicos. Este proceso debe validarse a través de mediciones in situ [12].

Los algoritmos de teledetección, para recuperar las propiedades de las aguas superficiales, incluyen clorofila-a, sólidos suspendidos totales, turbidez y otras [13]. Los modelos de regresión empírica se basan en ecuaciones lineales o exponenciales de reflectancia o radiancia detectadas remotamente [14]. El desarrollo de un algoritmo empírico requiere un análisis estadístico entre la medición de los componentes o propiedades del agua y los datos radiométricos [15]. Para analizar dichas propiedades, esos algoritmos requieren campañas de campo y, debido a la presencia de componentes múltiples y complejos en las aguas, el desarrollo de modelos globales no es factible; por ende, un enfoque adecuado consistiría en desarrollar modelos regionales validados [16].

El Área Metropolitana del Gran Resistencia (AMGR), en el noreste de Argentina, es la principal área urbana de la provincia del Chaco e incluye cuatro ciudades y 423.000 habitantes, según el último censo de 2022 [17]. Está emplazada en el valle de inundación del río Paraná y se desarrolla principalmente en el interfluvio del río Negro y el riacho Arazá. Las lluvias o sequías continuas modifican el patrón de los ríos y arroyos, generando lagunas de meandros [18]. Aunque el terreno del AMGR es plano, el ecosistema corresponde a un humedal y, como consecuencia, en el área urbana están insertos múltiples cursos y cuerpos de agua. En concordancia con esto, la estimación de la calidad del agua es sumamente relevante para evaluar el impacto humano en el ambiente, planificar medidas de corrección y evaluar sus efectos.

2 Área de estudio, por Enid Utgés

El río Paraná es el segundo río más largo de América del Sur, con 4000 km [19]. En Argentina, es el límite natural de múltiples provincias, hasta llegar al Río de la Plata, para terminar en el Océano Atlántico. El Paraná, posee un módulo anual de $17.300 \text{ m}^3/\text{s}$ producto de los aportes del río Alto Paraná (en la República de Paraguay) y del río Paraguay [20]. Este último, con 2550 km [19], es un afluente del río Paraná, en su cuenca media, en el Noreste argentino.

El río Paraguay recibe del río Bermejo un volumen considerable de sedimentos finos en suspensión, provenientes de la Cordillera de los Andes que se descargan en el río Paraná [21], [22]. A partir de la confluencia con el río Paraguay (frente a la localidad de Paso de la Patria, provincia de Corrientes), el río Paraná muestra marcadas diferencias espaciales y temporales en las concentraciones de esos sedimentos que modifican las características de la composición del agua. Debido a ello se generan dos regiones distintas: de alta (oeste) y baja (este) concentración de dichos sedimentos en suspensión [23].

Debido a las concentraciones tan dispares mencionadas en el párrafo anterior, la interfaz de mezcla entre las aguas donde dos grandes ríos se unen se puede visualizar claramente. No obstante, esa mezcla completa comúnmente requiere una longitud de río significativa y esa distancia puede extenderse a decenas e incluso cientos de kilómetros. Las observaciones de campo de la unión de los ríos Paraná y Paraguay, muestran que la longitud de mezcla puede ser mayor a 400 km (mezcla lenta) pero también tan baja como 8 km (mezcla rápida) [23]. En general, la visualización sólo puede manifestarse mediante mediciones de campo y datos de sensado remoto [24], [25], [26], [27].

A partir de la confluencia mencionada y su planicie de inundación, el río Paraná incorpora varios m^3/s en términos de caudales medios. El aporte de esos caudales es uno de los factores que altera el ciclo hidrológico; los otros que también pueden incidir son:

- Los parámetros como pH, temperatura, sólidos en suspensión, conductividad y turbidez también involucran procesos que los afectan [28].
- Las oscilaciones vinculadas a cambios climáticos a escala global como por ejemplo el ENOS (El Niño oscilación sur) en nuestro país [10], [29], [30], [31].
- Los efectos antrópicos [32], [33], [34], [35] modifican los procesos físico-químicos de los hábitats y los patrones de las comunidades biológicas, producen períodos de inundación, sequía y variaciones extremas del caudal (flujos bajos, altos, extremadamente altos, etc.).

El Paraná tiene un gran impacto en la sociedad del AMGR, específicamente sobre la industria pesquera, el turismo, las actividades recreativas de la población local y las rutas de transporte [36]. Es el recurso hídrico requerido por la planta potabilizadora, cuyas tomas de agua cruda

están ubicadas en dos sectores del mencionado río. Una de ellas, la más antigua, está ubicada sobre un brazo del río Paraná, el río Barranqueras; éste, a su vez, está conectado con dos ríos principales del área metropolitana que son los ríos Negro y Tragadero. A fines del 2023, entró en operaciones la nueva toma de agua situada sobre el canal principal de navegación del río Paraná, en una zona cercana al puente Gral. Belgrano que une las provincias de Chaco y Corrientes.

Dada la gran variabilidad en la cantidad de sedimentos presentes en el agua del Paraná, la planta potabilizadora necesita adaptar frecuentemente la operación de filtración; ésta es una etapa crítica del proceso, debido a la necesidad de dosificar agentes floculantes para asegurar la remoción de los sólidos. La aplicación de las técnicas de teledetección, en la recuperación de los datos espectrales del agua, tiene como objetivo crear un modelo que los estime de forma remota; asimismo, esas técnicas le brindarían a la empresa herramientas valiosas para la toma de decisiones.




Figura 1: Imagen satelital de la región de interés. Mapa superior: ubicación relativa a Argentina.

La región de interés, donde se hacen las campañas de campo se muestra en la figura 1. Los tres puntos señalados sobre el río Paraná se utilizaron para generar la figura 10.

3 Materiales y métodos

El diagrama mostrado en la figura 2 corresponde al flujo de trabajo para la obtención y generación de resultados.




Figura 2: Flujo de trabajo.

4 Muestreos

Los muestreos, según lo permita la logística, se llevan a cabo en la fecha de adquisición de Sentinel-2 (S2-MSI) cada 5 días sobre la región de interés, con cielo despejado. El plan de adquisición actualizado puede descargarse en formato .kml.

En cada fecha se toman 8 muestras de agua sobre una transecta a lo largo del río Paraná. Los sitios son aproximadamente equidistantes entre sí y con las orillas.

Fecha	Día
2025-12-04	Jueves
2025-12-11	Jueves
2025-12-16	Martes
2025-12-26	Viernes
2025-12-31	Miércoles
2026-01-05	Lunes
2026-01-15	Jueves
2026-01-20	Martes
2026-01-30	Viernes
2026-02-04	Miércoles
2026-02-09	Lunes

Tabla 1: **Fecha actual** y de los próximos 10 muestreos.

4.1 Metodología de muestreo

El calendario completo de muestreos para el resto del año se encuentra en el siguiente link.

Las muestras de agua se toman en botellas de vidrio color caramelo de 1 litro y se registra la posición geográfica del sitio.

In situ, se miden: pH, conductividad y profundidad de disco de Secchi (SDD). Luego, en el laboratorio se analizan turbidez y sólidos suspendidos totales (TSM). A continuación se describe cada parámetro fisicoquímico:

- pH y conductividad ($\mu\text{S}/\text{cm}$), a partir de un equipo multiparamétrico.
- Profundidad de disco de Secchi (cm).

En todos los casos, no se apreció la presencia de nubes sobre los puntos de toma de muestras.

Los ocho sitios muestrales se nombran correlativamente de P1 a P8, iniciando en la **orilla chaqueña** y finalizando en la **costa de Corrientes**.

5.2 Datos fisicoquímicos

Las siguientes figuras (4) muestran la evolución de las propiedades fisicoquímicos a lo largo de la longitud geográfica entre orillas y la fecha de muestreo.

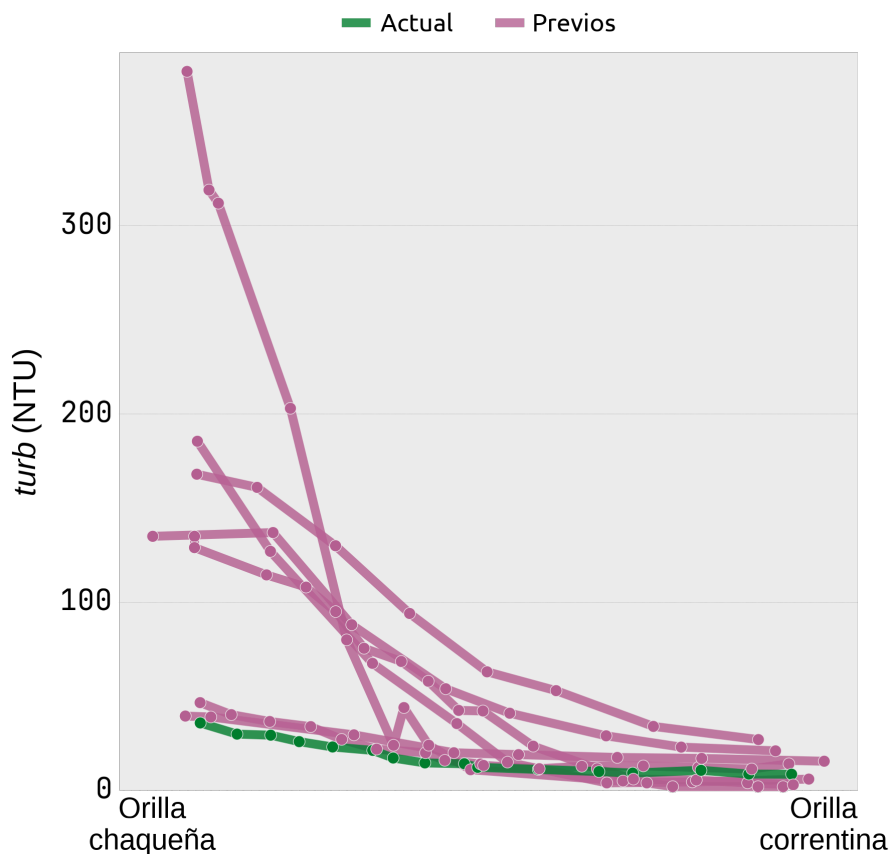


Figura 4: Evolución espacial y temporal de las propiedades del agua.

[Ver figuras interactivas en la versión online ↗](#)

Tabla de coeficientes de correlación lineal **R** (Pearson) entre pares de parámetros fisicoquímicos. Los valores se acomodan como una matriz triangular para evitar repeticiones.

La figura 5 muestra el coeficiente de correlación lineal de Pearson (r) entre pares de parámetros fisicoquímicos.




Figura 5: Mapa de calor de las correlaciones lineales entre parámetros fisicoquímicos. Con ★ se indica significancia estadística ($pvalor < 0,05$)

[Ver figura interactiva en la versión online ↗](#)

Es notable que el pH no se correlaciona con ninguna otra variable. Existe una correlación positiva ($r > 0,5$) entre la *turb* con *cond* y *susp*. En contraste, *secchi* se correlaciona de forma negativa ($r < 0,5$) con *turb*, *susp* y *cond*.

Las correlaciones mostradas en la figura 5 pueden visualizarse en las siguientes figuras (6). La línea punteada corresponde al mejor ajuste lineal para cada par de parámetros.




Figura 6: Figuras que muestran la relación entre parámetros. La **línea de trazos** indica el ajuste lineal como referencia.

Ver figuras en la versión online ↗

Las propiedades fisicoquímicas del agua cambian a lo largo de la transecta. Se divide el conjunto de datos en **lado Chaco** o **lado Corrientes**, según si la longitud geográfica de las observaciones son menores o mayores a la longitud media, respectivamente.

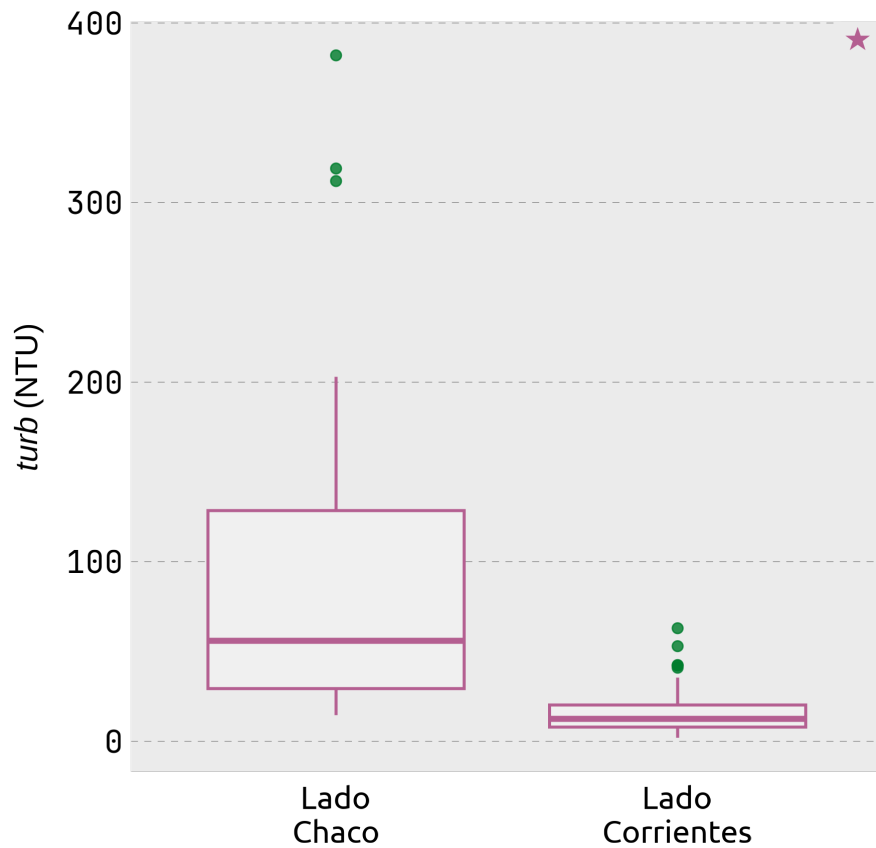


Figura 7: ★ = $pvalor < 0.05$, existe diferencia significativa entre los grupos

Ver el resto de las figuras en la versión online ↗

La figura 7 muestra que existe diferencias significativas entre ambas orillas para *turb*, *secchi*, *susp* y *cond*. pH se mantiene homogéneo a lo largo de la transecta al río Paraná.

6 Firmas espectrales

La reflectancia de superficie (ρ_r) [37] se define como el cociente entre la radiación reflejada por la superficie de interés (Φ_r) y la radiación solar incidente (Φ_i), a una longitud de onda específica (λ), de acuerdo a la ecuación 1.

$$\rho_r(\lambda) = \frac{\Phi_r(\lambda)}{\Phi_i(\lambda)} \quad (1)$$

Por definición, ρ_r adopta el rango entre 0 – 1.

Una definición más rigurosa [14] indica que la reflectancia de sensado remoto ($R_{rs}(\lambda)$) se expresa como el cociente entre la radiancia saliente del agua verticalmente ascendente ($L_w(\lambda)$) y la irradiancia verticalmente descendente sobre la superficie del agua ($E_d(0^+)$), a una longitud de onda λ , según la ecuación 2.

$$R_{rs}(\lambda) = \frac{L_w(\lambda)}{E_d(0^+)} \quad (2)$$

Con los pares ordenados de R_{rs} y λ para las bandas de S2-MSI, se construyen figuras que muestran el comportamiento espectral del agua, llamadas **firmas espectrales**, las cuales son específicas para cada cobertura y dan cuenta de algunas de sus propiedades.

A partir de los valores de píxel de las reflectancias de superficie se construyen firmas espectrales, que permiten inferir las características del agua. Las firmas espectrales a lo largo de la transecta en el río Paraná, sirven para ver el cambio entre costas.

El producto satelital empleado corresponde al de S2-MSI, nivel de procesamiento L1C, en reflectancia a tope de atmósfera, sin corrección atmosférica. El procesador ACOLITE fue utilizado para obtener los valores de reflectancia de superficie.

ACOLITE utiliza el *algoritmo dark spectrum fitting* [38], [39], [40] para la corrección atmosférica de múltiples plataformas satelitales con aplicaciones acuáticas. Los productos satelitales son procesados con ACOLITE para obtener un recorte de la escena alrededor de la región de interés.

Firmas espectrales por fecha y sitio muestral a lo largo de una línea transecta (figura 8).

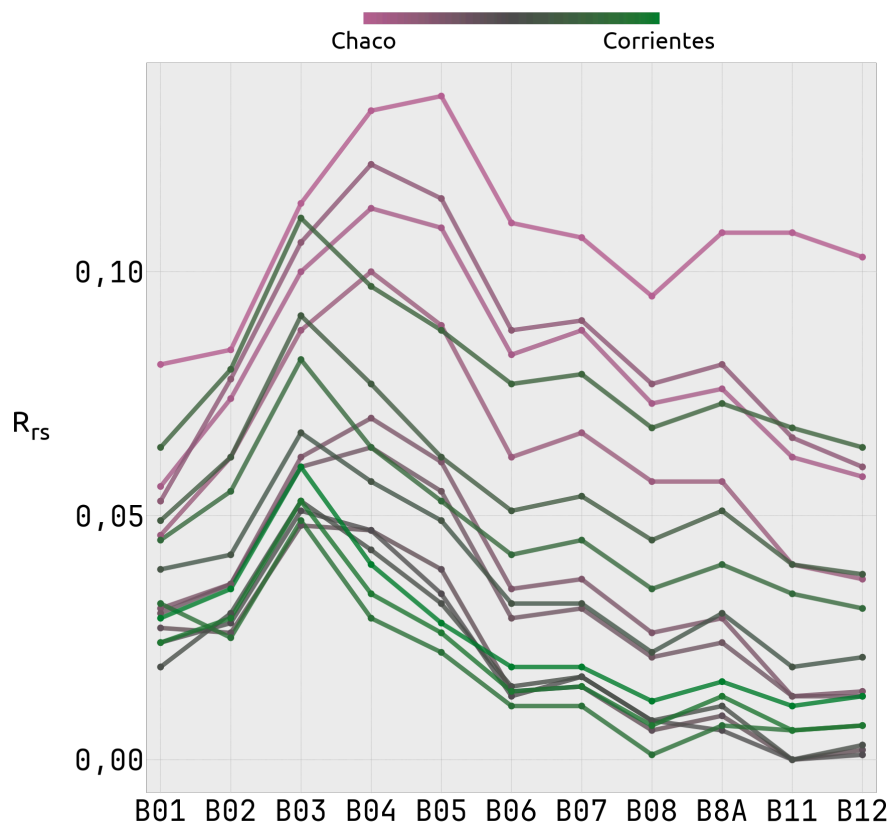


Figura 8: Firmas espectrales por sitio muestral y fecha.

[Ver figuras interactivas en la versión online ↗](#)

Las curvas de **color violeta** corresponden a los sitios cercanos a la orilla chaqueña. Los puntos próximos a la costa correntina son de **color verde**.

Generalmente, las firmas espectrales del lado chaqueño presentan los mayores valores. A medida que los sitios de muestreo se acercan al lado correntino, las firmas espectrales comienzan a aplanarse.

El efecto de las características cambiantes del agua no es el mismo para las bandas espectrales de S2-MSI, tal como se muestra en la figura 9.

La distribución (en formato de gráfico de cajas) de R_{rs} por banda, indica que en ciertas bandas se observa un efecto de la composición del agua más que en otras.

Las bandas B11 y B12 muestran una distribución estrecha, con bajos valores de reflectancia, a pesar de los cambios observados en el agua. En contraste, las bandas B04 y B05 abarcan un mayor rango de respuesta espectral y valores altos.

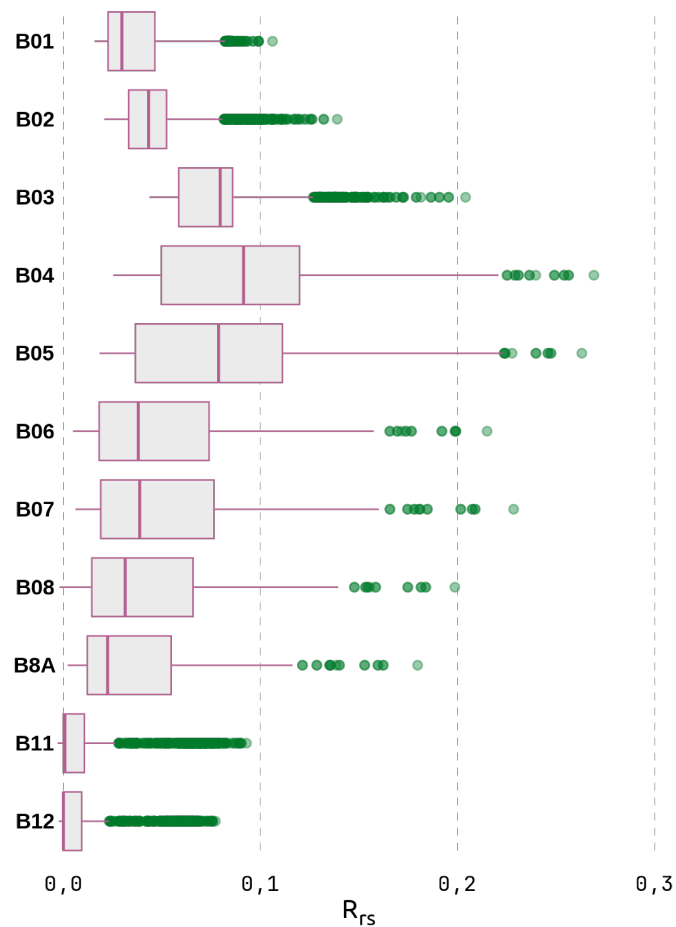


Figura 9: Distribución de reflectancia de superficie por banda espectral.

Se seleccionaron tres sitios fijos, mostrados en la figura 1, para extraer los valores de R_{rs} y evaluar el cambio en la respuesta espectral a lo largo del río Paraná.

La figura 10 muestra que las características de la composición del agua tiene poca repercusión para las bandas B11 y B12, dado que se mantienen constantes en los puntos extremos y en el medio del curso de agua.

En cambio, las bandas B04 y B05 muestran una notable disminución de la R_{rs} en dirección Chaco-Corrientes.




Figura 10: Distribución de R_{rs} a partir de gráficos de cajas por sitio fijo y banda espectral. ★ en la esquina de cada panel marca diferencia significativa ($pvalor < 0.05$) entre los conjuntos de la costa **chaqueña** y **correntina**.

Las características espectrales de S2-MSI se muestran en la siguiente tabla:

Banda	S2A			S2B		
	Resolución espacial (m)	Longitud de onda (nm)	Ancho de banda (nm)	Longitud de onda (nm)	Ancho de banda (nm)	
B01 (aerosol)	60	442,7	20	442,3	20	
B02 (blue)	10	492,7	65	492,3	65	
B03 (green)	10	559,8	35	558,9	35	
B04 (red)	10	664,6	38	664,9	31	
B05 (red edge)	20	704,1	14	703,8	15	
B06	20	740,5	14	739,1	13	
B07	20	782,8	19	779,7	19	
B08 (NIR)	10	832,8	105	832,9	104	
B8A	20	864,7	21	864,0	21	
B09	60	945,1	19	943,2	20	
B10	60	1373,5	29	1376,9	29	
B11 (SWIR 1)	20	1613,7	90	1610,4	94	
B11 (SWIR 2)	20	2202,4	174	2185,7	184	

Tabla 2: Propiedades de las bandas S2-MSI, para las plataformas S2A y S2B.

7 Discusión

Esta sección recolecta información bibliográfica referente a parámetros de laboratorio estimados mediante teledetección satelital.

Se eligieron tres propiedades del agua: turbidez, sólidos suspendidos y profundidad de disco de Secchi.

A continuación se muestran (según en caso) las ecuaciones para la estimación de las propiedades, los sensores y longitudes de onda empleados, las características de los cuerpos de agua y la justificación de los autores, junto con la referencia bibliográfica.

Se pretende poder justificar los algoritmos desarrollados propios a partir de los obtenidos por otros autores.

Las características de las bandas espectrales de S2-MSI se encuentran en la tabla 2.

- Métodos tradicionales

Ecuaciones directas, usualmente polinomios, de la forma general:

$$propiedad = f(\text{bandas espectrales})$$

Estas expresiones permiten evaluar la contribución de las bandas espectrales, y sus combinaciones, al valor de la propiedad fisicoquímica estimada.

Son usuales las expresiones que incorporan índices espectrales, sensibles a alguna característica del agua, como ser NDCI (índice normalizado de diferencia de clorofila) [41], [42], NDTI (índice normalizado de diferencia de turbidez) [43], entre otros.

- Aprendizaje automático

Las técnicas de aprendizaje automático permiten encontrar relaciones entre las propiedades del agua y la reflectancia de superficie, a distintas longitudes de onda.

7.1 Turbidez, por Víctor Gómez

La turbidez se refiere a la opacidad o falta de claridad en un líquido provocada por la presencia de partículas suspendidas. Este fenómeno es un indicador clave en el monitoreo de la calidad del agua y su influencia en diferentes ecosistemas es significativa.

La turbidez es un indicador de la calidad del agua, reflejando la presencia de partículas en suspensión. Su medición es crucial para garantizar la potabilidad del agua y la salud de los ecosistemas acuáticos. Este fenómeno puede ser resultado de diversas causas, como la erosión del suelo, la actividad biológica y la contaminación. La comprensión de la turbidez y su impacto es esencial para la gestión de recursos hídricos y la protección del medio ambiente.

La turbidez viene determinada por la dispersión de la luz causada por la materia suspendida en el agua, se obtiene normalmente mediante un turbidímetro, que proporciona medidas en Nephelometric Turbidity Unit (NTU) y mide la dispersión de un rayo de luz en el agua a 90° de la luz incidente [44].

Muchas propiedades, como la clorofila-a (Chl-a), sólidos suspendidos totales (SST) y la materia orgánica disuelta coloreada (CDOM), se utilizan a menudo como indicadores del estado del agua. Estos constituyentes del agua a su vez son responsables de la turbidez.

Existe una fuerte correlación entre turbidez y sólidos suspendidos totales, por lo que se puede estimar SST a partir de la turbidez. Por lo general, es una relación directa, a mayor concentración de SST mayor turbidez.

Existe una relación inversa entre la Turbidez y la profundidad del disco de Secchi (a valores bajos de Secchi mayor turbidez), por lo que también se puede estimar turbidez a partir de mediciones de disco de Secchi.

7.1.a Métodos tradicionales

Tabla 3: Características principales de algoritmos tradicionales para la estimación de turbidez.

Ecuación	Referencia
$1.559e^{35.533 \cdot B03}, 1.879e^{37.745(B03 \cdot B5)/(B04+B12)}$	[45]
$2677.2 \cdot B04^{1.856}$	[46]
$969 - 1.5468 \cdot R_{1200nm} + 2.07 \frac{B8A}{B02}$	[47]
$y = -1.1 + 5.8 \frac{B02}{B04}, y = 3.896 - 4.186 \frac{B02}{B03}$	[48]
$y = 37661 \cdot B8A^2 + 1845 \cdot B8A, y = 531.5 - \frac{B04}{0.88}$	[49]

Ver tabla completa en la versión online ↗

Múltiples modelos (lineal, logaritmos, inversa, cuadrática, exponencial, potencial) y plataformas (Sentinel-2, Landsat-5 y Landsat-8) emplean el cociente de bandas B04/B03 [50].

Modelos de estimación a partir de Sentinel-2 y Landsat-8 utilizan regresiones lineales, cuadráticas y logarítmicas empleando B02, B03, B04, B01 (con menos apariciones) y cocientes entre éstas [51].

7.1.b Métodos de aprendizaje automático

El aprendizaje automático es un subconjunto de la inteligencia artificial que permite que un sistema aprenda y mejore de forma autónoma, sin necesidad de una programación explícita, a través del análisis de grandes cantidades de datos. El aprendizaje automático permite que los sistemas informáticos se ajusten y mejoren continuamente a medida que acumulan más “experiencias”. Por lo tanto, el rendimiento de estos sistemas puede mejorar si se proporcionan conjuntos de datos más grandes y variados para su procesamiento.

Cuando se entrenan modelos de machine learning, cada conjunto de datos y cada modelo necesitan un conjunto diferente de “hiperparámetros”. Los hiperparámetros son variables de configuración externa que se utilizan para administrar el entrenamiento de modelos de machine learning. Controlan de forma directa la estructura, funciones y rendimiento de los modelos. Los hiperparámetros son los parámetros de un modelo de aprendizaje automático, que no se aprenden durante el entrenamiento, sino que se establecen antes de que comience.

El “ajuste de hiperparámetros” permite modificar el rendimiento del modelo para lograr resultados óptimos. Este proceso es una parte fundamental del machine learning. El ajuste de hiperparámetros puede ser manual o automático. A pesar de que el ajuste manual es lento y tedioso, permite entender mejor cómo afectan al modelo las ponderaciones de los hiperparámetros. El proceso de ajuste de hiperparámetros es iterativo, y debe probar diferentes combinaciones de parámetros y valores.

En el aprendizaje automático es importante utilizar técnicas de “validación cruzada”, de modo que el modelo no se centre únicamente en una única porción de sus datos. La validación cruzada o cross-validation es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. La idea básica de la validación cruzada es dividir los datos en conjuntos de entrenamiento y validación, y luego entrenar el modelo en el conjunto de entrenamiento y evaluar su rendimiento en el conjunto de validación. Este proceso se repite varias veces, con diferentes subconjuntos de los datos utilizados para el entrenamiento y la validación, y se calcula el rendimiento promedio.

En los procesos de machine learning supervisado se utilizan diversos algoritmos y técnicas de cálculo, generalmente calculados mediante el uso de programas como R o Python.

Dependiendo del tipo de datos que se usen para el entrenamiento, será de modelo de aprendizaje automático que se use. A grandes rasgos, existen tres tipos de modelos que se usan en el aprendizaje automático: aprendizaje supervisado, no supervisado y por refuerzo.

Consultando el trabajo de otros investigadores, se observa que utilizan principalmente el aprendizaje automático supervisado. Este tipo de aprendizaje supervisado utiliza un conjunto de entrenamiento para enseñar a los modelos a producir el resultado deseado. Este conjunto de datos de entrenamiento incluye entradas y salidas correctas, que permiten al modelo aprender

con el tiempo. El algoritmo mide su precisión a través de la función de pérdida, ajustando hasta que el error se haya minimizado lo suficiente.

Yang Zhe y otros, utilizaron como datos de entrada la reflectancia de superficie y datos de salida la turbidez, utilizaron los modelos SVR (support vector regression), random forest (RF) y eXtreme Gradiente Boosting (XGBoost). Los hiperparámetros de cada modelo se determinaron mediante una búsqueda en cuadrícula de validación cruzada en Scikit-Learn de Python [52].

Ma Yue y otros, utilizaron varios modelos de aprendizaje automático, usaron Python 3.7 tanto para la predicción de la turbidez del agua y la optimización de los hiperparámetros [45].

Zhao y otros probaron 14 modelos de machine learning en un estanque de peces con un dispositivo de construcción propia, de los cuales ETR, Bagging, RFR, and ABR son los que presentaron un mejor desempeño en la estimación de la turbidez. Los algoritmos se implementaron utilizando Python 3.6 y bibliotecas de aprendizaje scikit [53].

Tabla 4: Características principales de algoritmos de aprendizaje automático para la estimación de turbidez.

Modelo de machine learning	Referencia
SVR, ELM ,BP ,CART ,GBT ,RF ,KNN	[45]
eXtreme Gradient Boosting (XGBoost), support vector regression (SVR), random forest (RF)	[52]
linear regression (LR), ridge regression (RR), least absolute shrinkage and selection operator regression(LASSO), elastic net regression (ENR), k-nearest neighbor regression (KNN), Gaussian process regression (GPR), decision tree regression (DTR), support vector regression (SVR), multilayer perceptron regression (MLP), adaptive boosting regression (ABR), gradient boosting regression (GBR), bootstrap aggregating regression (Bagging), random forest regression (RFR), and extreme tree regression (ETR)	[53]

[Ver tabla completa en la versión online ↗](#)

7.2 Profundidad de disco de Secchi, por Mauricio Acosta

La transparencia del agua es uno de los componentes clave para describir la calidad y productividad de aguas naturales. Antes de la disponibilidad de radiómetros, el campo de luz bajo el agua era estimado sólo mediante la observación visual del disco de Secchi.

El disco de Secchi es **un instrumento de medición de la penetración luminosa**. Se utiliza midiendo la profundidad desde la superficie de masa de agua que el disco alcanza hasta perderse de vista.

El disco de Secchi sigue siendo utilizado debido a la simplicidad y rango de aplicación universal del método, además de tratarse de un parámetro fácilmente entendible por el público.

La profundidad de disco de Secchi es influenciada por tres componentes ópticos principales: clorofila-a, materia orgánica disuelta coloreada, y sólidos suspendidos totales.

Como se señaló en el apartado de turbidez, se observa una relación inversa entre esta y la profundidad de disco de Secchi.

7.2.a Métodos tradicionales

Las ecuaciones principales propuestas son de tipo **logarítmica** o **potencial**, lo cual tiene sentido considerando que la relación entre la reflectancia y la turbidez no es lineal. No obstante, algunas ecuaciones lineales presentan un buen desempeño. En ambos tipos de ecuación se repite la presencia de un **cociente** entre bandas.

Tabla 5: Características principales de algoritmos de aprendizaje automático para la estimación de profundidad de disco de Secchi.

Ecuación	Referencia
$A \left[\frac{R_{rs}(\lambda_1)}{R_{rs}(\lambda_2)} \right]^B$	[54]
$e^{a \left[\frac{R_{rs}(\lambda_1)}{R_{rs}(\lambda_2)} \right] + b}$	[55]
$A \left[\frac{R_{rs}(\lambda_1)}{R_{rs}(\lambda_2)} \right]^B$	[44]
$1.79 - 134.15 \cdot B_{RE1} + 157.72 \cdot B_{NIR} + 0.52 \frac{B_{RES}}{NIR_n}$	[2]
$\log(SDD) = -3.0257 - 1.4379 \cdot \log(R_{B8A}) - 0.127[\log(R_{B8A})]^2$	[56]

Ver tabla completa en la versión online ↗

7.2.b Métodos de aprendizaje automático

A modo de identificar y aprender los patrones subyacentes en las series de datos para asegurar la transferibilidad a través de espacio y tiempo de los distintos modelos obtenidos se destaca el uso de algoritmos como **Random Forest** y la aplicación de **Redes neuronales**.

Los **modelos de regresión mediante random forest**, construidos utilizando las bandas previamente halladas por modelos algebraicos, demostraron explicar de manera consistente una mayor variabilidad que otros algoritmos, indicado por un mayor *pseudo* – R^2 . Se señala además que los algoritmos con el mejor rendimiento tienden a ser aquellos que incluye bandas del infrarrojo cercano.

Una alternativa con un rendimiento superior a los modelos regresión resulta de aplicación de **redes neuronales convolucionales de una dimensión**. Estas aplican operaciones de convolución y extracción de características en la dimensión espectral de una imagen multiespectral, permitiendo encontrar patrones complejos y relaciones entre las características y el valor medido.

La información se procesa interpretando a los datos como unidimensionales, representando a los valores de reflectancia tomados en todas las longitudes de onda disponibles para una única profundidad medida. La hipótesis es que la relación entre la reflectividad de distintas bandas, capturadas utilizando convolución, codifica la claridad del cuerpo de agua medido como profundidad de disco de Secchi.

7.3 Sólidos suspendidos totales, por Vera Geneyer

Los sólidos suspendidos totales (TSM): es la cantidad de materia en suspensión en el agua, que incluye plancton, minerales, arena, y microorganismos. Se determinan como el residuo no

filtrable de una muestra de agua. Niveles altos (TSM) pueden reducir la transparencia del agua, limitar la luz y transportar sustancias tóxicas, afectando la vida acuática y la calidad del agua. Este parámetro, medido mediante sensores remotos, nos da información sobre el estado físico del cuerpo de agua y están relacionados con factores como la humedad, temperatura y entre otros, que es vital para detectar riesgos al ecosistema y cumplir con las normas ambientales.

7.3.a Métodos tradicionales

Tabla 6: Características principales de algoritmos tradicionales para la estimación de sólidos suspendidos.

Ecuación	Referencia
$-229.34\left(\frac{B03}{B08}\right)^3 + 1001.65\left(\frac{B03}{B08}\right)^2 - 1422.7\left(\frac{B03}{B08}\right) + 665.17$	[57]
$-244.83 + 40.21 \cdot B01 - 3.67 \cdot NDWI$	[58]

Ver tabla completa en la versión online ↗

De acuerdo a un estudio que analizó 48 cuerpos de agua, la estimación de TSM se hizo en su mayoría por modelos lineales, siendo la banda B8A la más frecuente [59].

7.3.b Métodos de aprendizaje automático

El **aprendizaje automático (ML)** es una rama de la inteligencia artificial cuyo objetivo es desarrollar algoritmos capaces de resolver problemas mediante el análisis de datos y la creación de funciones que describen el comportamiento de fenómenos monitoreados [60]. Los modelos de aprendizaje automático más utilizados y mencionados por los investigadores para predecir la concentración de SST son:

- **Bosque Aleatorio (RF) y Refuerzo Adaptativo (AdB)**, modelos que se destacan por su robustez ante datos complejos y ruidosos. Estos algoritmos construyen múltiples árboles de decisión que analizan las relaciones entre características como el uso del suelo o el volumen de escorrentía y los niveles de SST [61].
- **Redes Neuronales Artificiales (ANN)**, copian las redes neuronales biológicas y aprenden patrones complejos en grandes volúmenes de datos, como los niveles de SST en distintas condiciones ambientales [61],
- **k-Nearest Neighbors (kNN)**, en sus variantes de ponderación uniforme y variable, que estima el SST en función de la cercanía en características de nuevos puntos de muestreo con datos históricos [61].

El aprendizaje automático es esencial para mejorar la precisión y rapidez en el análisis de la calidad del agua, proporcionando un monitoreo más eficiente y menos costoso en comparación con los métodos tradicionales, especialmente en áreas de difícil acceso o con datos limitados.

Tabla 7: Características principales de algoritmos de aprendizaje automático para la estimación de sólidos suspendidos.

Modelo de machine learning	Referencias
Bagging y Random Forest	[60]
Regresión lineal, LASSO, regresión de vectores de soporte (SVR), K vecinos más cercanos (KNN), bosque aleatorio (RF) y redes neuronales artificiales (ANN).	[62]
Regresión lineal, regresión de vectores de soporte (SVR), K vecinos más cercanos (KNN), bosque aleatorio (RF) y redes neuronales artificiales (ANN).	[61]

[Ver tabla completa en la versión online ↗](#)

8 Objetivos

El objetivo principal del proyecto de investigación es:

Modelar la calidad del agua en una porción de la cuenca media del río Paraná mediante el desarrollo de un algoritmo construido a partir de técnicas estadísticas, información espacial y datos de campo.

8.1 Objetivos específicos

- Seleccionar un sector de la cuenca media del río Paraná, en la confluencia de los ríos Paraguay-Paraná, y en la toma de agua de la empresa potabilizadora de la ciudad de Resistencia.
- Definir la cantidad y ubicación geográfica de los sitios de muestreo considerando el sensor satelital elegido, la logística y las características de la región de interés.
- Analizar los sólidos suspendidos y la turbidez como indicadores de la calidad del agua en las muestras recolectadas en los sitios previamente seleccionados.
- Construir una base de datos espaciotemporales a partir de productos satelitales ópticos, en reflectancia de superficie.
- Calcular índices espectrales relacionados con la cuantificación de los indicadores de calidad del agua.
- Desarrollar un algoritmo semiempírico que permita estimar indicadores de la calidad del agua a partir de los datos de campo y los datos espectrales de los productos espaciales.
- Validar el algoritmo desarrollado, evaluar su significancia estadística y compararlo con otros encontrados en referencias bibliográficas.
- Generar mapas de los parámetros estimados y su evolución temporal a partir de la aplicación del algoritmo obtenido.
- Analizar espaciotemporalmente el comportamiento de los indicadores de calidad de agua.
- Formar RRHH en el área específica.

El desarrollo de algoritmos empíricos requiere de datos espectrales y fisicoquímicos del agua, la propuesta de modelos candidatos, la selección final de los modelos y la validación de los mismos. Luego, la generación de mapas para evaluar la distribución espacial de las propiedades.

Se pretende automatizar la descarga, extracción y almacenamiento de los datos espectrales y fisicoquímicos del agua en los sitios de muestreo, junto con las coordenadas geográficas.

A medida que el proyecto avance, los resultados parciales serán registrados en el presente sitio web, para su seguimiento y revisión por parte de los integrantes.

9 Algoritmos

La estimación de los parámetros fisicoquímicos se llevó a cabo mediante el desarrollo de algoritmos de regresión por mecanismos de aprendizaje automático.

Se indican a continuación los resultados de los algoritmos obtenidos para turbidez, profundidad de disco de Secchi y sólidos disueltos.

9.1 Turbidez, por Víctor Gómez

El modelo desarrollado para la estimación de turbidez en el agua del río Paraná fue XGBoost. Los hiperparámetros fueron optimizados con búsqueda bayesiana inteligente.

La figura 11 muestra la turbidez estimada y medida. Las métricas de desempeño dieron: $R^2 = 0,92$ y $RMSE = 11,282NTU$.




Figura 11: Estimaciones y mediciones de turbidez del modelo seleccionado.

La distribución espacial de turbidez en el río Paraná se muestra en la figura 12.

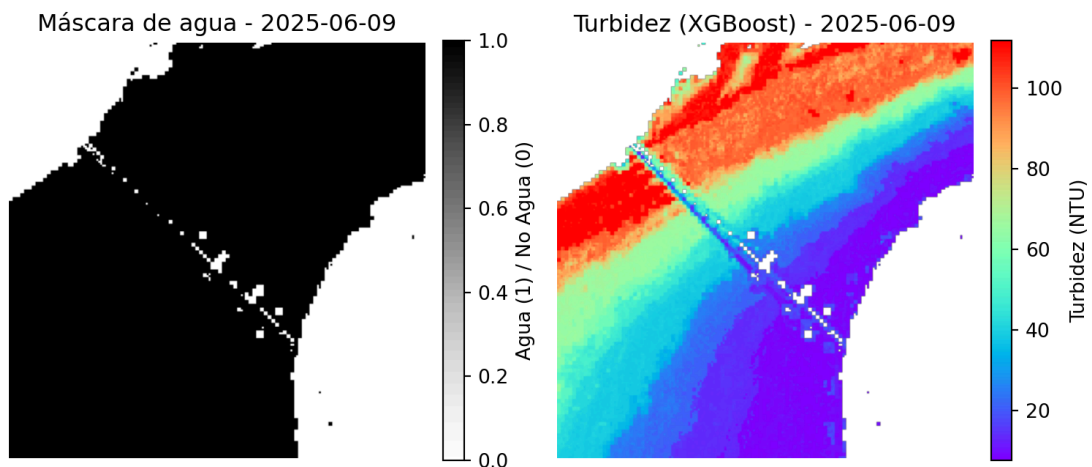


Figura 12: Máscara de agua y mapa de turbidez correspondiente al 2025-06-09.

El desarrollo del algoritmo, su optimización y más detalles se encuentran en el siguiente enlace.

9.2 Profundidad de disco de Secchi, por Mauricio Acosta

Las estimaciones de transparencia del agua se lograron con un algoritmo de aprendizaje automático XGBoost. El mismo presentó $R^2 = 0,8636$ y $RMSE = 231,55cm$.

La comparación entre profundidad de disco de Secchi estimado y medido puede observarse en la figura 13.

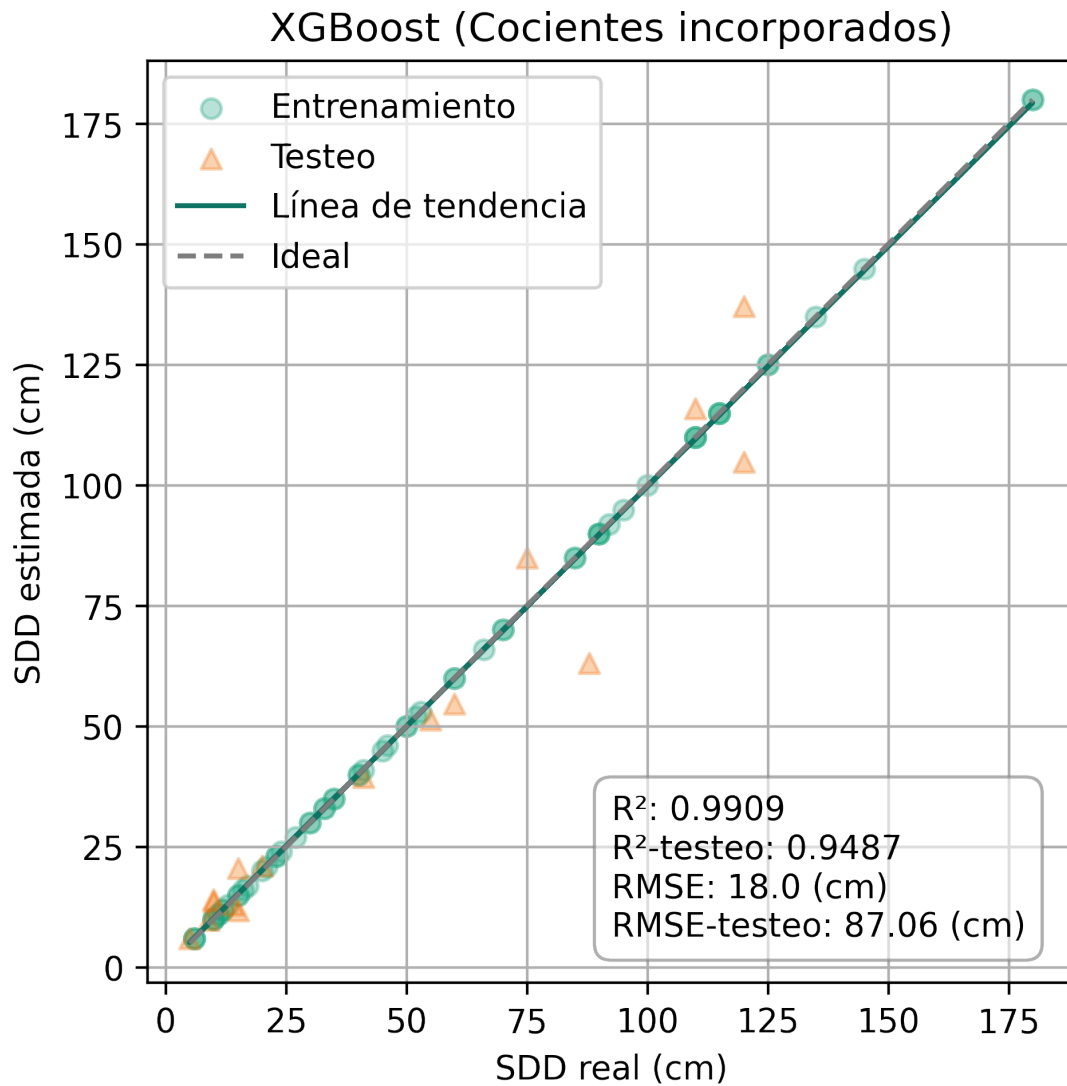


Figura 13: Estimaciones y mediciones de profundidad de disco de Secchi del modelo seleccionado.

Para más información respecto del algoritmo desarrollado, dirigirse al siguiente link.

9.3 Sólidos suspendidos totales, por Ariadna Seba

El modelo que presentó los mejores resultados fue *random forest*.

La concentración de sólidos mostró la siguiente distribución espacial de la figura 14.

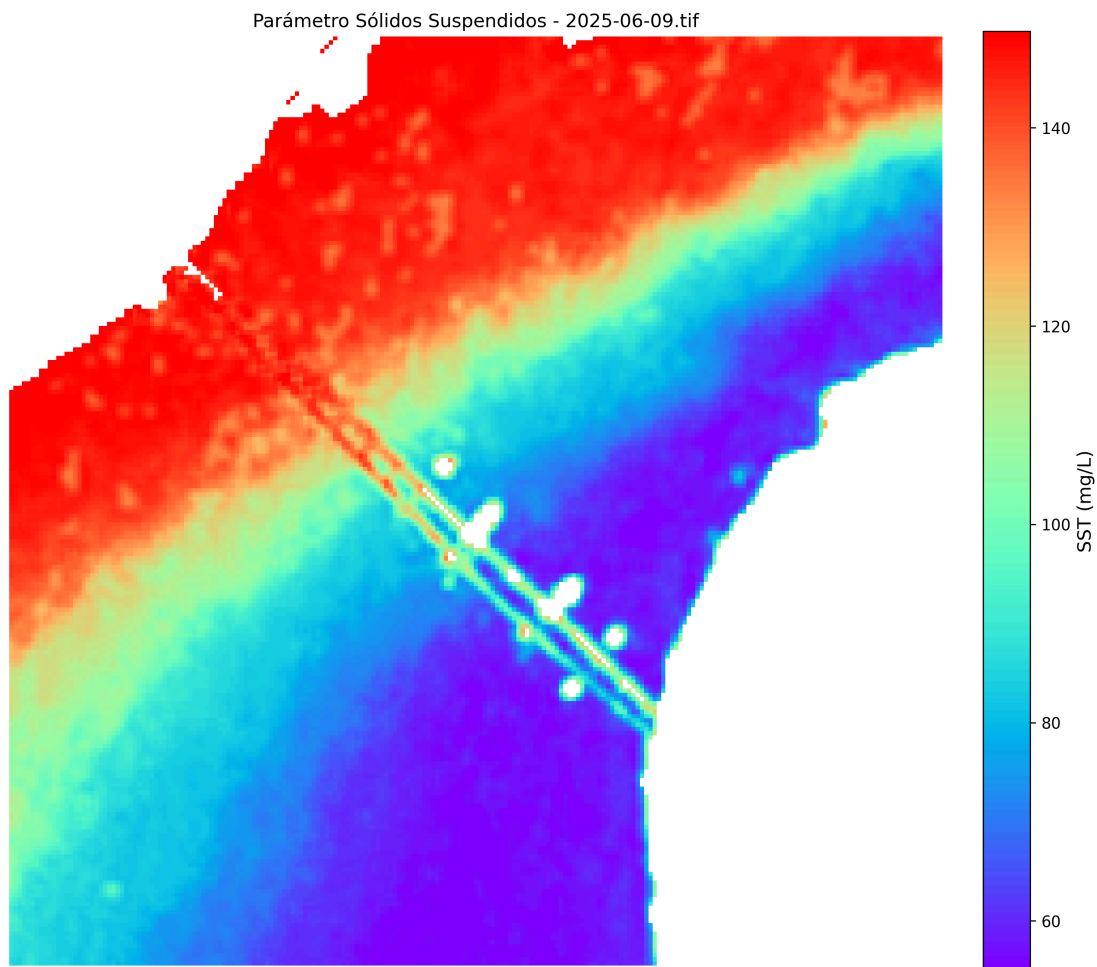


Figura 14: Mapa de sólidos disueltos correspondiente al 2025-06-09.

El desarrollo completo del algoritmo se encuentran en el siguiente sitio.

10 Contacto

Integrantes del Proyecto de Investigación.

Profesionales:

- **Enid Utgés**
- **Daniela Tenev**
- **Víctor Gauto**

Becarios:

- **Mauricio Acosta**
- **Vera Geneyer**
- **Víctor Gómez**
- **Bruno Lossada Dusset**
- **Ariadna Seba**
- **Noelia Molo**

Los archivos que generan este sitio web están disponibles en

Sitio web desarrollado y mantenido por: **Víctor Gauto** ✉ 🌐

Grupo de Investigación Sobre Temas Ambientales y Químicos (**GISTAQ**) ✉ 📷 🌐.

Bibliografía

- [1] United Nations General Assembly, «Work of the Statistical Commission Pertaining to the 2030 Agenda for Sustainable Development», 2017.
- [2] M. Bonansea *et al.*, «Evaluating the feasibility of using Sentinel-2 imagery for water clarity assessment in a reservoir», *Journal of South American Earth Sciences*, vol. 95, 2019, doi: 10.1016/j.jsames.2019.102265.
- [3] M. H. Gholizadeh, A. M. Melesse, y L. Reddi, «A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques», *Sensors (Switzerland)*, vol. 16, n.º 8, 2016, doi: 10.3390/s16081298.
- [4] A. Ferral *et al.*, «In-Situ and Satellite Monitoring of Water Quality of an Eutrophic Lake with an Artificial Air Diffusion System», *IEEE Latin America Transactions*, vol. 16, n.º 2, pp. 627-633, 2018, doi: 10.1109/TLA.2018.8327422.
- [5] J. Gorroño, A. C. Banks, N. P. Fox, y C. Underwood, «Radiometric Inter-Sensor Cross-Calibration Uncertainty Using a Traceable High Accuracy Reference Hyperspectral Imager», *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 130, pp. 393-417, ago. 2017, doi: 10.1016/j.isprsjprs.2017.07.002.
- [6] D. Phiri, M. Simwanda, S. Salekin, V. Nyirenda, Y. Murayama, y M. Ranagalage, «Sentinel-2 Data for Land Cover/Use Mapping: A Review», *Remote Sensing*, vol. 12, n.º 14, p. 2291, jul. 2020, doi: 10.3390/rs12142291.
- [7] S. Wang *et al.*, «Water Color from Sentinel-2 MSI Data for Monitoring Large Rivers: Yangtze and Danube», *Geo-Spatial Information Science*, 2023, doi: 10.1080/10095020.2023.2258950.
- [8] J. Bramich, C. J. Bolch, y A. Fischer, «Improved Red-Edge Chlorophyll-a Detection for Sentinel 2», *Ecological Indicators*, vol. 120, ene. 2021, doi: 10.1016/j.ecolind.2020.106876.
- [9] G. Liu *et al.*, «Remote Sensing of CDOM and DOC in Alpine Lakes across the Qinghai-Tibet Plateau Using Sentinel-2A Imagery Data», *Journal of Environmental Management*, vol. 286, may 2021, doi: 10.1016/j.jenvman.2021.112231.
- [10] M. A. Lovino, O. V. Müller, E. H. Berbery, y G. V. Müller, «How have daily climate extremes changed in the recent past over northeastern Argentina?», *Global and Planetary Change*, vol. 168, n.º June, pp. 78-97, 2018, doi: 10.1016/j.gloplacha.2018.06.008.
- [11] E. L. Hestir *et al.*, «Measuring Freshwater Aquatic Ecosystems: The Need for a Hyperspectral Global Mapping Satellite Mission», *Remote Sensing of Environment*, vol. 167, pp. 181-195, 2015, doi: 10.1016/j.rse.2015.05.023.
- [12] J. Hogg, «Quantitative Remote Sensing of Land Surfaces», *The Photogrammetric Record*, vol. 19, n.º 108, pp. 413-415, dic. 2004, doi: 10.1111/j.0031-868X.2004.295_1.x.
- [13] V. Sagan *et al.*, «Monitoring Inland Water Quality Using Remote Sensing: Potential and Limitations of Spectral Indices, Bio-Optical Simulations, Machine Learning, and Cloud

- Computing», *Earth-Science Reviews*, vol. 205, n.º April, p. 103187, jun. 2020, doi: 10.1016/j.earscirev.2020.103187.
- [14] X. Chen y L. Feng, «Remote Sensing of Lakes' Water Environment», Elsevier, 2018, pp. 249-277. doi: 10.1016/B978-0-12-409548-9.10408-7.
- [15] I. Ogashawara, D. R. Mishra, y A. A. Gitelson, *Remote Sensing of Inland Waters: Background and Current State-of-the-Art*. Elsevier Inc., 2017. doi: 10.1016/B978-0-12-804644-9.00001-X.
- [16] H. Yang, J. Kong, H. Hu, Y. Du, M. Gao, y F. Chen, «A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges», *Remote Sensing*, vol. 14, n.º 8, abr. 2022, doi: 10.3390/rs14081770.
- [17] Instituto Nacional de Estadística y Censos (Argentina), *Censo Nacional de Población, Hogares y Viviendas 2022 : Resultados Provisionales / c Instituto Nacional de Estadística y Censos (Argentina)*. 2022.
- [18] S. A. Poi de Neiff, C. A. Patiño, J. J. Neiff, y A. O. Ramos, «Calidad Del Agua En El Tramo Bajo Del Río Negro (Chaco, Argentina)», *FACENA*, vol. 19, n.º 2, pp. 67-85, 2003.
- [19] A. A. Bonetto, J. J. Neiff, y D. H. D. Persia, «The Paraná River system», 1986, pp. 541-598. doi: 10.1007/978-94-017-3290-1_11.
- [20] L. A. Espínola *et al.*, «Discrimination of hydrologic variations for spatial distribution of fish assemblage in a large subtropical temperate river», *Ecohydrology*, vol. 13, n.º 2, 2020, doi: 10.1002/eco.2163.
- [21] M. L. Amsler y E. C. Drago, «A review of the suspended sediment budget at the confluence of the Paraná and Paraguay Rivers», *Hydrological Processes*, vol. 23, n.º 22, pp. 3230-3235, 2009, doi: 10.1002/hyp.7390.
- [22] O. Orfeo y J. Stevaux, «Hydraulic and morphological characteristics of middle and upper reaches of the Paraná River (Argentina and Brazil)», *Geomorphology*, vol. 44, pp. 309-322, 2002.
- [23] S. N. Lane, D. R. Parsons, J. L. Best, O. Orfeo, R. A. Kostaschuk, y R. J. Hardy, «Causes of rapid mixing at a junction of two large rivers: Río Paraná and Río Paraguay, Argentina», *Journal of Geophysical Research: Earth Surface*, vol. 113, n.º 2, 2008, doi: 10.1029/2006JF000745.
- [24] J. R. Mackay, «Lateral mixing of the Liard and Mackenzie rivers downstream from their confluence», vol. 7, pp. 111-124, 1970.
- [25] J. K. H R; Mackay, «Application of H2'80/H2160 Abundances to the Problem of Lateral Mixing in the Liard-Mackenzie River System», vol. 8. p. 1107, 1971.
- [26] E. Matsui, F. Salati, I. Friedman, y W. L. Brinkman, «Isotopic hydrology in the Amazonia: 2. Relative discharges of the Negro and Solimões rivers through 18O concentrations», *Water Resources Research*, vol. 12, n.º 4, pp. 781-785, 1976, doi: 10.1029/WR012i004p00781.
- [27] R. F. Stallard, «Cross-channel mixing and its effect on sedimentation in the Orinoco River», *Water Resources Research*, vol. 23, n.º 10, pp. 1977-1986, 1987, doi: 10.1029/WR023i010p01977.

- [28] G. M. F. R. C. Espínola Yoya, «Bases para estudiar las alteraciones del régimen hidrológico y su importancia ecológica en la Argentina», *Ecología Austral-Asociación Argentina de Ecología*, vol. 32, pp. 273-296, 2022.
- [29] A. I. Pasquini y P. J. Depetris, «Southern Patagonia's Perito Moreno Glacier, Lake Argentino, and Santa Cruz River hydrological system: An overview», *Journal of Hydrology*, vol. 405, n.º 1-2, pp. 48-56, 2011, doi: 10.1016/j.jhydrol.2011.05.009.
- [30] V. Y. Bohn, A. L. Delgado, M. C. Piccolo, y G. M. Perillo, «Assessment of climate variability and land use effect on shallow lakes in temperate plains of Argentina», *Environmental Earth Sciences*, vol. 75, n.º 9, 2016, doi: 10.1007/s12665-016-5569-6.
- [31] A. C. de la Casa, G. G. Ovando, y G. J. Díaz, «ENSO influence on corn and soybean yields as a base of an early warning system for agriculture in Córdoba, Argentina», *European Journal of Agronomy*, vol. 129, 2021, doi: 10.1016/j.eja.2021.126340.
- [32] M. M. Santiago; Acuña, «Navegando el Paraná Apuntes de dos investigadores desde la línea de flotación», *Revista de Política, Derecho y Sociedad*, 2021, [En línea]. Disponible en: <http://revistabordes.com.ar/>
- [33] K. Ferreira, T. M. Lopes, I. de Paiva Affonso, A. A. Agostinho, y L. C. Gomes, «Dam reverse flow events influence limnological variables and fish assemblages of a downstream tributary in a Neotropical floodplain», *River Research and Applications*, vol. 36, n.º 2, pp. 305-313, 2020, doi: 10.1002/rra.3584.
- [34] M. R. Acuña, «¿Qué pasa en las islas? Jóvenes y experiencias formativas en contexto de pandemia y bajante del río Paraná», *Millcayac - Revista Digital de Ciencias Sociales*, vol. 2, pp. 367-388, 2020, [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=525868774015>
- [35] E. Abrial, R. E. Lorenzón, A. P. Rabuffetti, M. C. Blettler, y L. A. Espínola, «Hydroecological implication of long-term flow variations in the middle Paraná river floodplain», *Journal of Hydrology*, vol. 603, 2021, doi: 10.1016/j.jhydrol.2021.126957.
- [36] J. J. Neiff, A. S. G. P. D. Neiff, y S. L. Casco, «Ecological importance of the Paraguay-Paraná River Corridor as a context for sustainable management, in Spanish», *Humedales fluviales de América del Sur*, pp. 193-210, 2005.
- [37] E. Chuvieco, *Fundamentos de teledetección espacial*, 2da ed. Rialp, 1996.
- [38] Q. Vanhellemont y K. Ruddick, «Atmospheric correction of metre-scale optical satellite data for inland and coastal water applications», *Remote Sensing of Environment*, vol. 216, n.º March, pp. 586-597, 2018, doi: 10.1016/j.rse.2018.07.015.
- [39] Q. Vanhellemont, «Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives», *Remote Sensing of Environment*, vol. 225, n.º November2018, pp. 175-192, 2019, doi: 10.1016/j.rse.2019.03.010.
- [40] Q. Vanhellemont, «Daily metre-scale mapping of water turbidity using CubeSat imagery», *Optics Express*, vol. 27, n.º 20, p. A1372, 2019, doi: 10.1364/oe.27.0a1372.
- [41] S. Mishra y D. R. Mishra, «Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters», *Remote Sensing of Environment*, vol. 117, pp. 394-406, 2012, doi: 10.1016/j.rse.2011.10.016.

- [42] W. G. Buma y S. I. Lee, «Evaluation of Sentinel-2 and Landsat 8 images for estimating Chlorophyll-a concentrations in Lake Chad, Africa», *Remote Sensing*, vol. 12, n.º 15, 2020, doi: 10.3390/RS12152437.
- [43] J. P. Lacaux, Y. M. Tourre, C. Vignolles, J. A. Ndione, y M. Lafaye, «Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley Fever epidemics in Senegal», *Remote Sensing of Environment*, vol. 106, n.º 1, pp. 66-74, 2007, doi: 10.1016/j.rse.2006.07.012.
- [44] J. Delegido *et al.*, «Turbidity and secchi disc depth with sentinel-2 in different trophic status reservoirs at the comunidad valenciana», *Revista de Teledeteccion*, vol. 2019, n.º 54, pp. 15-24, 2019, doi: 10.4995/raet.2019.12603.
- [45] Y. Ma *et al.*, «Remote sensing of turbidity for lakes in Northeast China using sentinel-2 images with machine learning algorithms», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 9132-9146, 2021, doi: 10.1109/JSTARS.2021.3109292.
- [46] A. K. Hossain, C. Mathias, y R. Blanton, «Remote sensing of turbidity in the tennessee river using landsat 8 satellite», *Remote Sensing*, vol. 13, n.º 18, 2021, doi: 10.3390/rs13183785.
- [47] M. Najafzadeh y S. Basirian, «Evaluation of River Water Quality Index Using Remote Sensing and Artificial Intelligence Models», *Remote Sensing*, vol. 15, n.º 9, 2023, doi: 10.3390/rs15092359.
- [48] M. Allam, M. Y. A. Khan, y Q. Meng, «Retrieval of turbidity on a spatio-temporal scale using landsat 8 SR: A case study of the Ramganga River in the Ganges Basin, India», *Applied Sciences (Switzerland)*, vol. 10, n.º 11, 2020, doi: 10.3390/app10113702.
- [49] Y. Luo, D. Doxaran, y Q. Vanhellemont, «Retrieval and validation of water turbidity at metre-scale using Pleiades satellite data: A case study in the Gironde Estuary», *Remote Sensing*, vol. 12, n.º 6, 2020, doi: 10.3390/rs12060946.
- [50] M. Shen, S. Wang, Y. Li, M. Tang, y Y. Ma, «Pattern of turbidity change in the middle reaches of the yarlung zangbo river, southern tibetan plateau, from 2007 to 2017», *Remote Sensing*, vol. 13, n.º 2, pp. 1-25, 2021, doi: 10.3390/rs13020182.
- [51] Y. O. Ouma, K. Noor, y K. Herbert, «Modelling Reservoir Chlorophyll- a, TSS, and Turbidity Using Sentinel-2A MSI and Landsat-8 OLI Satellite Sensors with Empirical Multivariate Regression», *Journal of Sensors*, vol. 2020, 2020, doi: 10.1155/2020/8858408.
- [52] Z. Yang *et al.*, «Combined Retrievals of Turbidity from Sentinel-2A/B and Landsat-8/9 in the Taihu Lake through Machine Learning», *Remote Sensing*, vol. 15, n.º 17, 2023, doi: 10.3390/rs15174333.
- [53] Y. Zhao *et al.*, «Retrieval of Water Quality Parameters Based on Near-Surface Remote Sensing and Machine Learning Algorithm», *Remote Sensing*, vol. 14, n.º 21, 2022, doi: 10.3390/rs14215305.
- [54] K. Alikas y S. Kratzer, «Improved retrieval of Secchi depth for optically-complex waters using remote sensing data», *Ecological Indicators*, vol. 77, pp. 218-227, 2017, doi: 10.1016/j.ecolind.2017.02.007.

- [55] M. Pereira-Sandoval *et al.*, «Calibration and validation of algorithms for the estimation of chlorophyll-a concentration and secchi depth in inland waters with Sentinel-2», *Limnetica*, vol. 38, n.º 1, pp. 471-487, 2019, doi: 10.23818/limn.38.27.
- [56] J. Delegido, C. Tenjo, A. Ruiz-Verdu, y M. Pereira-Sandoval, «Aplicaciones de Sentinel-2 a estudios de vegetación y calidad de aguas continentales». [En línea]. Disponible en: <https://www.researchgate.net/publication/312040510>
- [57] D. C. R. Ramírez, «Método de Estimación de Sólidos Suspendedos Totales como Indicador de la Calidad del Agua Mediante Imágenes Satelitales». 2017.
- [58] G. D. J. L., J. Stephan, y Delance-Martinic., «Determinación del parámetro sólidos suspendidos totales (sst) mediante imágenes de sensores ópticos en un tramo de la cuenca media del río Bogotá (Colombia).», *UD y la Geomática*, pp. 19-27, 2014, doi: 10.14483/udistrital.jour.udgeo.2014.9.a02.
- [59] A. Cruz-Retana, C. Fonseca-Ortiz, R. Becerril-Piña, M. A. Gómez-Albores, M. Hernández-Téllez, y R. Arévalo-Mejía, «Characterization of spectral reflectance and TSS concentration in continental water bodies worldwide», vol. 1. pp. 4-18, 2023.
- [60] E. E. C. Vargas, «Modelamiento de Relaciones entre Parámetros Físicoquímicos y Microbiológicos en Aguas de la Bahía Interior del Lago Titicaca-Puno (Perú) mediante Árboles de Predicción», *Revista Técnica De La Facultad De Ingeniería Universidad Del Zulia*, vol. 44, n.º 3, pp. 154-168, 2021, doi: 10.22209/rt.v44n3a02.
- [61] M. Moeini, A. Shojaeizadeh, y M. Geza, «Supervised machine learning for estimation of total suspended solids in urban watersheds», *Water (Switzerland)*, vol. 13, n.º 2, 2021, doi: 10.3390/w13020147.
- [62] L. S. Kupssinskü, T. T. Guimarães, E. M. D. Souza, y D. C. Zanotta, «A method for chlorophyll-a and suspended solids prediction through remote sensing and machine learning», *Sensors (Switzerland)*, vol. 20, n.º 7, 2020, doi: 10.3390/s20072125.