





Aplicación de métodos de aprendizaje profundo para la imputación de niveles de concentración de clorofila-a en la Costa Pacífica colombiana

Applying Deep Learning Methods for the Imputation of Chlorophyll-a Concentration Levels in the Colombian Pacific Coast

Aplicação de Métodos de Aprendizado Profundo para a Imputação dos Níveis de Concentração de Clorofila-a na Costa do Pacífico Colombiano

Luis-Miguel Martínez-Vargas¹  

Julián-Fernando Muñoz-Ordóñez²  

Yady-Tatiana Solano-Correa³  

Recibido: 23 de mayo de 2024

Aceptado: 30 de agosto de 2024

Para citar este artículo: Martínez-Vargas, L. M., Muñoz-Ordóñez, J. F. y Solano-Correa, Y. T. (2024). Aplicación de métodos de aprendizaje profundo para la imputación de niveles de concentración de clorofila-a en la Costa Pacífica colombiana. *Revista Científica*, 50(2), 85-99. <https://doi.org/10.14483/23448350.22614>

Resumen

El sector pesquero en Colombia, que aporta el 0.3 % del Producto Interno Bruto (PIB) y genera exportaciones por USD 45.1 millones (equivalente al 3.3 % del PIB agropecuario), enfrenta desafíos significativos debido a la falta de precisión en la medición de la clorofila-a, un indicador crucial de la salud de los ecosistemas marinos. El uso de imágenes satelitales, particularmente aquellas obtenidas por el sensor MODIS, es esencial para obtener datos precisos. Sin embargo, la alta cobertura nubosa, común en la geografía colombiana, afecta la calidad y la disponibilidad de estas imágenes durante gran parte del año, creando lagunas en los datos críticos para la evaluación del estado de los ecosistemas marinos. Este trabajo propone un algoritmo de aprendizaje profundo basado en series temporales para la predicción de valores perdidos de clorofila-a. La metodología presentada supera las limitaciones impuestas por la cobertura nubosa, alcanzando una precisión R^2 superior a 0.8 en uno de los modelos. En este contexto específico, la implementación y la evaluación de diversos modelos de aprendizaje profundo han demostrado ser alternativas efectivas para proporcionar una evaluación más precisa y continua de las áreas pesqueras. Esto ofrece información valiosa para mejorar la gestión y sostenibilidad del sector pesquero en Colombia al añadir un componente temporal a la predicción de valores de clorofila-a. Esto, mediante datos de hasta tres meses previos a la característica objetivo.

Palabras clave: aprendizaje profundo; clorofila-a; cobertura nubosa; MODIS; predicción de valores perdidos; sector pesquero; series temporales.

1. Corporación Universitaria Comfacauca (Popayán-Cauca, Colombia). luismartinez@unicomfacauca.edu.co
2. Corporación Universitaria Comfacauca (Popayán-Cauca, Colombia). julianfer@unicomfacauca.edu.co
3. Ph. D. Universidad Tecnológica de Bolívar (Cartagena-Bolívar, Colombia). solanoy@utb.edu.co

Abstract

The fishing sector in Colombia, which contributes 0.3% of the Gross Domestic Product (GDP) and generates USD 45.1 million in exports (equivalent to 3.3% of the agricultural GDP), faces significant challenges due to the lack of precision in measuring chlorophyll-a, a crucial indicator of marine ecosystem health. The use of satellite images, particularly those obtained by the MODIS sensor, is essential for obtaining accurate data. However, the high cloud cover, which is common in Colombian geography, affects the quality and availability of these images for much of the year, creating gaps in critical data for assessing the state of marine ecosystems. This work proposes a deep learning algorithm based on time series for predicting missing chlorophyll-a values. The presented methodology overcomes the limitations imposed by cloud cover, achieving an R² accuracy above 0.8 in one of the models. In this specific context, the implementation and evaluation of various deep learning models have proven to be effective alternatives in providing a more accurate and continuous assessment of fishing areas. This offers valuable information to improve the management and sustainability of the fishing sector in Colombia by adding a temporal component to the prediction of chlorophyll-a values, using data from up to three months prior to the target feature.

Keywords: chlorophyll-a; cloud cover; deep learning; fishing sector; missing value prediction; MODIS; time series.

Resumo

O setor pesqueiro na Colômbia, que contribui com 0,3% do Produto Interno Bruto (PIB) e gera exportações de USD 45,1 milhões (equivalente a 3,3% do PIB agropecuário), enfrenta desafios significativos devido à falta de precisão na medição da clorofila-a, um indicador crucial da saúde dos ecossistemas marinhos. O uso de imagens de satélite, particularmente aquelas obtidas pelo sensor MODIS, é essencial para a obtenção de dados precisos. No entanto, a alta cobertura de nuvens, comum na geografia colombiana, afeta a qualidade e a disponibilidade dessas imagens durante grande parte do ano, criando lacunas nos dados críticos para a avaliação do estado dos ecossistemas marinhos. Este trabalho propõe um algoritmo de aprendizado profundo baseado em séries temporais para a predição de valores ausentes de clorofila-a. A metodologia apresentada supera as limitações impostas pela cobertura de nuvens, atingindo uma precisão R² superior a 0,8 em um dos modelos. Nesse contexto específico, a implementação e a avaliação de diversos modelos de aprendizado profundo demonstraram ser alternativas eficazes para proporcionar uma avaliação mais precisa e contínua das áreas de pesca. Isso oferece informações valiosas para melhorar a gestão e a sustentabilidade do setor pesqueiro na Colômbia, ao adicionar um componente temporal à predição dos valores de clorofila-a, utilizando dados de até três meses anteriores à característica-alvo.

Palavras-chaves: aprendizado profundo; clorofila-a; cobertura de nuvens; MODIS; predição de valores ausentes; séries temporais; setor pesqueiro.

INTRODUCCIÓN

El sector pesquero tiene un impacto significativo en la economía colombiana, aportando el 0.3 % del Producto Interno Bruto (PIB) y generando exportaciones valoradas en USD 45.1 millones, lo que representa el 3.3 % del PIB agropecuario. La vasta extensión de las costas de Colombia y la riqueza de sus cuerpos de agua interiores hacen que la pesca sea una actividad vital para la sostenibilidad de sus comunidades y su seguridad alimentaria. Sin embargo, la gestión eficiente del sector se enfrenta a varios retos importantes, especialmente en lo que respecta al monitoreo de la clorofila-a (Chl-a), un indicador esencial de la salud de los ecosistemas marinos.

Una acción clave para potenciar la actividad económica en regiones pesqueras es la detección de bancos de peces, lo que permite a los pescadores gestionar mejor los recursos y contribuye a la conservación del ecosistema marino, evitando así daños ambientales. La teledetección satelital ha sido aplicada con éxito en la segmentación de bancos de peces, cubriendo amplias áreas marítimas ([Chuvienco Salinero, 2002](#)). La concentración de Chl-a es un indicativo importante de la presencia de peces ([Baudena et al., 2021](#)), y su medición precisa depende en gran medida de imágenes satelitales capturadas por sensores como el MODIS (*moderate resolution imaging spectroradiometer*) ([Salomonson et al., 2006](#)). Si bien existen métodos alternativos como el muestreo *in situ* y las boyas equipadas con sensores, estos presentan limitaciones en cuanto a cobertura espacial y frecuencia de datos. El muestreo manual es costoso ([Papenfus et al., 2020](#)) y se limita a pequeñas áreas, mientras que los sensores en boyas ofrecen monitoreo continuo, pero solo en ubicaciones puntuales. En contraste, la teledetección satelital permite obtener datos en tiempo real y a gran escala, lo que es esencial para el monitoreo extensivo, por ejemplo, de la costa pacífica colombiana. Aunque el sensor MODIS es ampliamente utilizado para medir la Chl-a, no es la única fuente de datos espectrales; satélites como el Sentinel-2 y el Landsat-8 también proporcionan información relevante ([Poddar et al., 2019](#)). Sin embargo, como se discutirá más adelante, la elección de MODIS en este estudio se basó en su alta frecuencia temporal y la disponibilidad de datos desde el año 2000, lo que permite análisis de series temporales más extensos. La costa del Pacífico, caracterizada por una alta incidencia de cobertura nubosa que afecta la dinámica de los ecosistemas ([Wilson & Jetz, 2016](#)), presenta desafíos tanto para MODIS como para otros satélites, resaltando la necesidad de emplear técnicas avanzadas de reconstrucción de datos. Entre ellas, las basadas en aprendizaje profundo son cruciales para estimar valores perdidos y mejorar la continuidad de los datos.

Estas imágenes satelitales proporcionan series temporales fundamentales para evaluar concentraciones de Chl-a a lo largo del tiempo. Sin embargo, la densa nubosidad en la región dificulta la recolección de datos precisos durante todo el año. Este estudio propone una metodología basada en aprendizaje profundo (*deep learning*) y series temporales para predecir valores perdidos de Chl-a en imágenes satelitales afectadas por la nubosidad.

En los últimos años, numerosos estudios se han centrado en la predicción de niveles de Chl-a mediante teledetección, empleando diversas técnicas de aprendizaje automático. Entre estas destacan métodos como el algoritmo Random Forest (RF) ([Breiman, 2001](#)) y el *bagging* ([G. Wang et al., 2011](#)), los cuales han demostrado ser efectivos en la construcción de modelos de pronóstico. Se destaca una aplicación de RF ([Yajima & Derot, 2018](#)) en la que se recopilaban datos desde 1999 hasta 2010 para prevenir sesgos en el aprendizaje del modelo. Además, se ha explorado el uso de técnicas de aprendizaje profundo, como las redes neuronales artificiales, en el control de la proliferación de algas ([H. Wang et al., 2015](#)). De igual manera, se han empleado máquinas de soporte vectorial (SVM) para predecir valores de Chl-a en embalses ([Park et al., 2015](#)), y se ha investigado la combinación de varios modelos para mejorar la precisión del pronóstico ([Li et al., 2018](#)). Otro enfoque que ha ganado relevancia es el uso de modelos de memoria a corto y largo plazo (LSTM). Estos modelos, junto con otras técnicas de aprendizaje automático, han sido exitosamente empleados para construir modelos de predicción de Chl-a ([Cho & Park, 2019](#)), al igual que una variedad de técnicas para generar modelos de aprendizaje automático que predigan valores de Chl-a ([Shin et al., 2020](#); [Hänninen et al., 2022](#); [Li et al., 2018](#)). Además, la integración de múltiples fuentes de datos y técnicas en un enfoque combinado ha permitido mejorar significativamente la precisión de las predicciones ([Eze et al., 2021](#)).

La implementación de técnicas de teledetección para obtener imágenes detalladas ([Abbas et al., 2019](#)) ha demostrado ser de gran utilidad, especialmente cuando se combinan con modelos de aprendizaje

profundo ([Ma et al., 2019](#)). Esta combinación es clave para lograr predicciones precisas de valores de Chl-a, como se evidencia en el trabajo de [Silveira Kupssinskü et al. \(2020\)](#), quienes emplearon datos de diferentes resoluciones espaciales derivados de imágenes espectrales de Sentinel-2. El uso de modelos de aprendizaje automático permite realizar predicciones con distintas ventanas de tiempo. Por ejemplo, en el estudio de [Du et al. \(2018\)](#) se desarrolló un modelo de redes neuronales entrenado con datos de concentración de Chl-a en imágenes de 48 x 27 píxeles. En [Dash et al. \(2022\)](#) se empleó un modelo de predicción basado en RF que utilizaba datos del satélite Sentinel-2 para medir la calidad del agua durante sequías, prediciendo los niveles de Chl-a. Sin embargo, estos estudios no consideraron la presencia de nubes en algunas imágenes, lo cual también se observa en investigaciones como las de [Yu et al. \(2022\)](#) y [Nascimento Silva et al. \(2018\)](#). Por otro lado, [Hu et al. \(2023\)](#) desarrollaron un proyecto enfocado en la construcción de modelos de redes neuronales para monitorear la concentración de Chl-a a través de imágenes de teledetección, utilizando las bandas más relevantes de las imágenes de Sentinel-2. Estos autores determinaron que el modelo óptimo incluía 12 bandas de imágenes de Sentinel-2 como entradas y una capa oculta con ocho neuronas. Cabe destacar que las imágenes se obtuvieron en condiciones climáticas despejadas, con mínima nubosidad y sin presencia de hielo, lo que mejoró significativamente la calidad de los datos y las predicciones del modelo, excluyendo ciertos rangos temporales afectados por la nubosidad.

En lo que respecta a modelos de aprendizaje profundo, [Chen et al. \(2024\)](#) presentaron un nuevo método llamado *Fourier transform convolutional long short-term memory* (FTC-LSTM), diseñado para estimar de manera más precisa la concentración de Chl-a en los ecosistemas marinos utilizando imágenes satelitales. El modelo FTC-LSTM combina técnicas de transformación de Fourier y redes neuronales recurrentes para superar estos desafíos y obtener estimaciones más precisas de Chl-a, incluso en áreas con alta cobertura de nubes. Adicionalmente, desarrollaron un método híbrido para predecir a largo plazo la concentración de Chl-a en lagos, utilizando técnicas como la descomposición de series temporales (STL), el análisis de coherencia de ondículas y las redes neuronales profundas (CNN-BiLSTM). La descomposición STL separa las tendencias a largo plazo de los componentes estacionales y residuales, mientras que la coherencia de ondículas identifica relaciones entre la Chl-a y factores ambientales, permitiendo a la CNN-BiLSTM capturar patrones complejos para obtener predicciones más precisas.

En comparación con otras regiones donde se ha estudiado la Chl-a mediante teledetección, como el Mar Mediterráneo o el Golfo de México, la Costa Pacífica colombiana presenta desafíos adicionales debido a su clima tropical, caracterizado por una alta incidencia de nubosidad y fenómenos como El Niño y La Niña ([Essien et al., 2022](#)). Estas condiciones limitan la disponibilidad de imágenes satelitales continuas, lo que hace necesario el uso de técnicas avanzadas para estimar los valores faltantes de Chl-a. En regiones templadas como el Mar Báltico ([Stramska & Jakacki, 2024](#)), donde la nubosidad es menos frecuente, se ha demostrado que es más fácil obtener series temporales parciales, lo que subraya la dificultad intrínseca del área de estudio mencionada. Esto resalta la necesidad de realizar un estudio temporal para el periodo 2000-2023 de imágenes satelitales MODIS mediante el uso de modelos de aprendizaje profundo, con el fin de recuperar valores perdidos a causa de coberturas nubosas en el Océano Pacífico colombiano. El análisis de series temporales de Chl-a es crucial debido a la alta variabilidad de este parámetro a lo largo del tiempo, que está influenciada por factores ambientales como la luz, la temperatura y los nutrientes. Identificar y comprender estos patrones es fundamental para la gestión sostenible de los recursos pesqueros y la conservación de los ecosistemas marinos. Los cambios en la biomasa fitoplanctónica, reflejados en la concentración de Chl-a, impactan directamente en la cadena alimentaria y, por ende, en la abundancia de especies como los peces. Además, la capacidad de predecir estos eventos ofrece a los

gestores marinos la posibilidad de implementar estrategias proactivas para mitigar impactos negativos y asegurar la sostenibilidad a largo plazo.

La implementación de esta metodología supera las limitaciones impuestas por la cobertura nubosa y proporciona una herramienta robusta para la evaluación continua y precisa de las áreas pesqueras en Colombia. Los resultados obtenidos a partir de este modelo son cruciales para una mejor gestión y planificación del sector pesquero, alineándose con las necesidades de sostenibilidad y desarrollo del país.

METODOLOGÍA

Área de interés

El área de estudio ([Figura 1](#)) seleccionada para esta investigación es la Costa Pacífica colombiana, que abarca aproximadamente 1300 km de litoral. Esta región es de gran importancia ecológica y económica, y alberga diversas poblaciones que dependen de los recursos marinos. Según el informe del Instituto de Investigaciones Marinas y Costeras (INVEMAR) sobre el estado de los ambientes y recursos marinos, la planificación marítima es esencial para la gestión sostenible de estas áreas, así como la vigilancia de las actividades humanas que podrían impactar negativamente en los ecosistemas locales. Dada su ubicación en la zona tropical (cerca del ecuador) la Costa Pacífica colombiana está sujeta a la convergencia de diferentes corrientes de aire, lo que genera una alta frecuencia de nubosidad a lo largo del año. Además, las extensas áreas selváticas que se encuentran a lo largo de la costa contribuyen a esta constante presencia de nubes ([Essien et al., 2022](#)). Esta característica geográfica presenta un desafío significativo para la obtención de imágenes satelitales libres de nubes, lo cual es crucial para una medición precisa de Chl-a. La nubosidad actúa como un obstáculo que limita la captura de datos continuos y confiables, por lo que la predicción de valores de Chl-a mediante modelos de aprendizaje profundo es esencial para superar estas limitaciones y mejorar la gestión de los recursos marinos en la región.

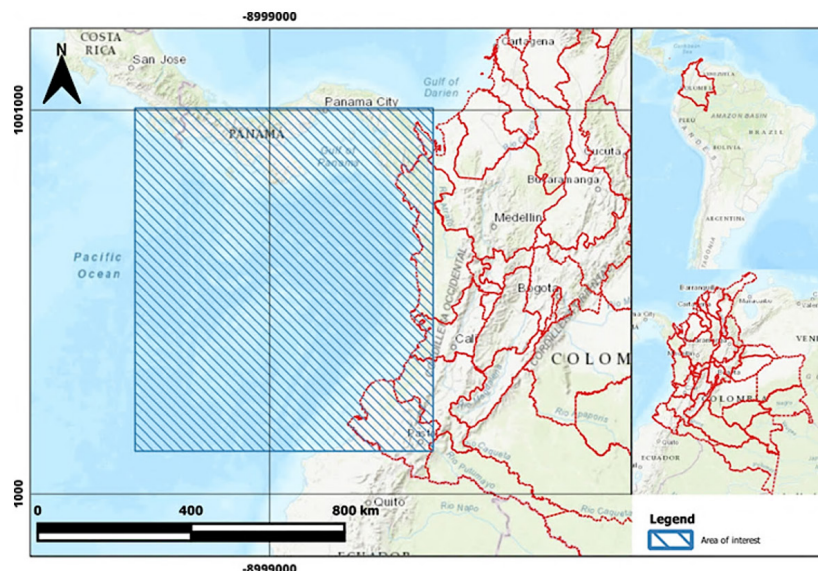


Figura 1. Área de interés – Costa Pacífica colombiana

Metodología para el pronóstico temporal de valores de Chl-a

En este estudio se desarrolla un enfoque basado en aprendizaje profundo para la predicción de valores perdidos de Chl-a en la Costa Pacífica colombiana. La metodología propuesta (Figura 2) consta de varios pasos clave para asegurar la calidad y la precisión de los resultados obtenidos por el algoritmo de predicción. El primer paso consiste en la adquisición de imágenes satelitales del sensor MODIS, las cuales proporcionan datos críticos sobre la concentración de Chl-a en las áreas de interés. Debido a la alta presencia de nubosidad en la región, es común que estas imágenes contengan zonas con datos faltantes. El siguiente paso implica el preprocesamiento de las imágenes, que incluye corrección radiométrica y geométrica para mejorar la calidad y la consistencia de la información, así como la aplicación de técnicas de correregistro, lo que implica, por ejemplo, usar mosaicos que contengan información relacionada con el tamaño y las coordenadas que deben tener las imágenes en común. Esto, en aras de que cada píxel de una imagen corresponda con los de las demás, lo que permite comparaciones precisas (Barazzetti *et al.*, 2014). Posteriormente, las imágenes satelitales se segmentan en píxeles y se preparan los conjuntos de datos necesarios para entrenar los modelos de aprendizaje profundo. Estos modelos están diseñados para trabajar con diferentes ventanas temporales, con el objetivo de estimar los valores faltantes de Chl-a en los píxeles de las imágenes. Para ello, se utilizan datos de los píxeles correspondientes en imágenes anteriores (de hasta tres meses previos), lo que permite predecir los valores actuales de Chl-a de manera precisa, píxel a píxel. Finalmente, el algoritmo genera nuevas imágenes, en las cuales se han imputado los valores faltantes, superando así las limitaciones de la nubosidad y proporcionando datos más completos y útiles para la gestión de los recursos marinos.

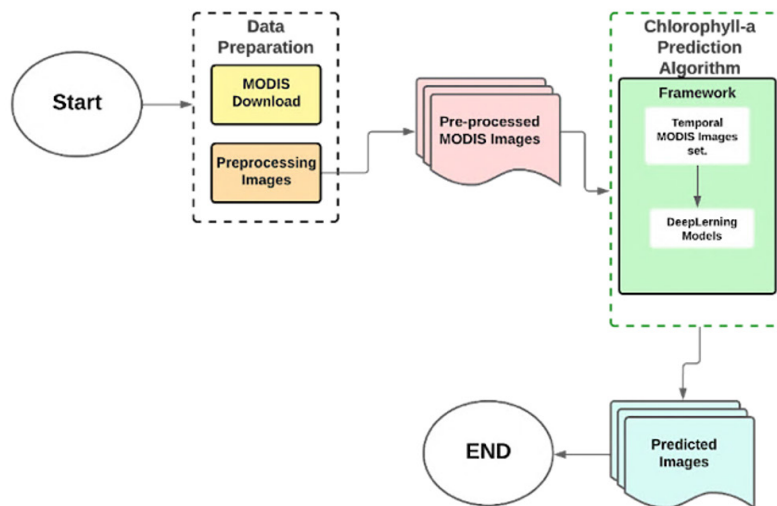


Figura 2. Metodología propuesta para el pronóstico de valores de clorofila

Algoritmo para el pronóstico temporal de valores de Chl-a

Para abordar el desafío de estimar valores faltantes de Chl-a en imágenes satelitales, se desarrolló un *framework* compuesto por seis módulos especializados. Este enfoque modular permite la subdivisión de tareas específicas, resultando en un código mantenible, escalable y adaptado a las necesidades del análisis temporal. Cada módulo del *framework* tiene funciones concretas, a saber:

- **MODIS Image Loader.** Este módulo carga las imágenes MODIS originales, que son luego corregidas y alineadas para asegurar la coherencia temporal y espacial. **BuilderDataset.** Tras alinear las imágenes, este módulo crea y guarda los conjuntos de datos necesarios para el entrenamiento de los modelos de predicción.
- **NETCDFModule.** Aquí, las imágenes y los conjuntos de datos procesados se guardan en formato NetCDF, facilitando el acceso y el manejo eficiente de grandes volúmenes de datos.
- **Trainer.** Este módulo se dedica al entrenamiento de modelos de aprendizaje profundo mediante los *datasets* preparados. Estos modelos son entrenados para predecir valores de Chl-a, utilizando datos de varios meses previos.
- **Predictor.** Una vez entrenados, los modelos son implementados en este módulo, que también maneja el procesamiento de las imágenes y la aplicación de máscaras de nubes para generar las predicciones finales.
- **Tester.** Este módulo final integra los modelos entrenados con las imágenes temporales para realizar predicciones precisas de Chl-a en la región de estudio. La estructura y flujo de trabajo de estos módulos se ilustra en la Figura 3, que proporciona una visión clara de la interacción de los componentes con el fin producir resultados confiables y valiosos para la gestión y conservación de los recursos marinos.

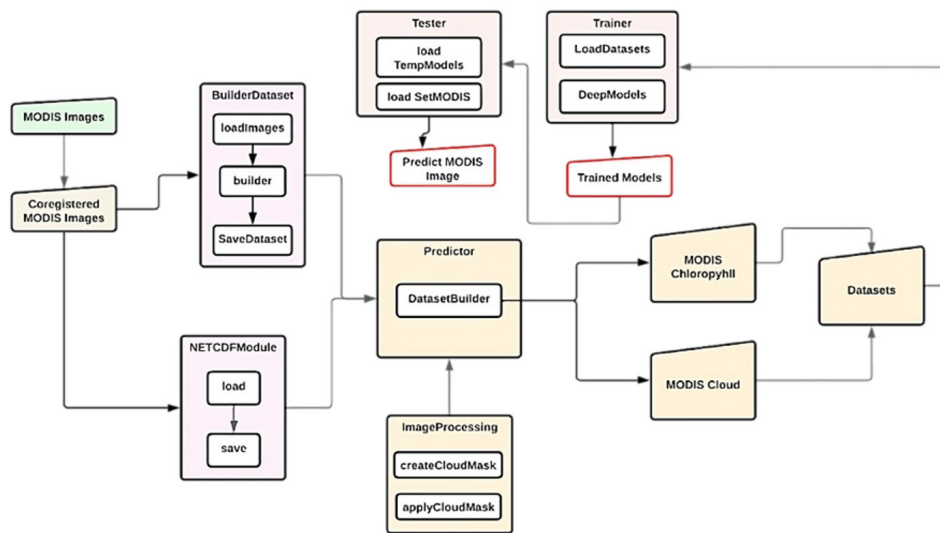


Figura 3. Diagrama del framework para el pronóstico de valores de Chl-a

El *framework* desarrollado para la predicción temporal de valores de Chl-a en imágenes MODIS se compone de seis módulos principales, cada uno diseñado para realizar tareas específicas que, en conjunto, permiten una estimación precisa y confiable. El primer módulo, MODIS Image Loader, se encarga de la carga inicial de las imágenes MODIS. Estas imágenes, cruciales para el análisis, son sometidas a un proceso de corrección y alineación espacial (*coregistering*), asegurando la coherencia temporal y espacial necesaria para el análisis posterior. A continuación, el módulo BuilderDataset toma las imágenes corregidas y las procesa para crear los conjuntos de datos requeridos para entrenar los modelos de predicción. Dentro de este módulo, primero se cargan las imágenes mediante la función *loadImages*, y luego se organizan y preparan en un formato adecuado por la función *builder*, lo que facilita el proceso de entrenamiento. Finalmente, el módulo guarda estos conjuntos de datos procesados utilizando *SaveDataset*, asegurando que estén listos para ser utilizados en las etapas de entrenamiento de modelos.

El NETCDFModule tiene un papel fundamental en el manejo de los datos, pues se encarga de guardar tanto los conjuntos de datos como las imágenes procesadas en formato NetCDF. Este formato es particularmente útil por su eficiencia en el manejo de grandes volúmenes de datos, lo que facilita su acceso y procesamiento en etapas posteriores del flujo de trabajo. El módulo Trainer es donde se lleva a cabo el entrenamiento de los modelos de aprendizaje profundo. Este módulo utiliza los conjuntos de datos generados previamente y los carga mediante *LoadDatasets*. Posteriormente, con la función *DeepModels* se entrenan los modelos que serán utilizados para predecir los valores de Chl-a. Estos modelos profundos están diseñados para aprovechar la información temporal, utilizando datos de varios meses anteriores para realizar predicciones más precisas.

Una vez entrenados los modelos, el módulo Tester los integra con las imágenes temporales, en aras de facilitar la predicción en nuevas imágenes MODIS. Este proceso comienza con la carga de los modelos temporales entrenados a través de *load TempModels*, así como de las imágenes MODIS alineadas mediante *load SetMODIS*. Con todo preparado, se realiza la predicción de los valores de Chl-a utilizando *Predict MODIS Image*, generando una estimación basada en el historial temporal de las imágenes.

Para la creación de los conjuntos de datos, primero se procesaron las imágenes satelitales de Chl-a junto con sus respectivas máscaras de nubes. Las imágenes fueron alineadas y corregidas para asegurar que los píxeles correspondieran a la misma ubicación geográfica a lo largo del tiempo. Luego, se recorrieron todos los píxeles de las imágenes, verificando la validez de los datos a lo largo de un período de nueve meses. El proceso consistió en revisar los píxeles correspondientes a cada mes, comenzando desde septiembre y retrocediendo hasta enero. Si se encontraban valores válidos en todos los meses, se guardaban los datos en el conjunto correspondiente. Este procedimiento permitió generar varios *datasets*, cada uno correspondiente a diferentes períodos de tiempo. Por ejemplo, un conjunto de datos podría incluir los valores de Chl-a para un mes específico, mientras que otros podrían incluir hasta tres meses consecutivos. A continuación, se presenta la [Ecuación \(1\)](#), que crea los conjuntos de datos:

Sean:

- I_m el valor del píxel en la posición (i,j) de la imagen de Chl-a correspondiente al mes m
- M_m la máscara de nubes en la posición (i,j) de la imagen correspondiente al mes m
- m un índice que va de 0 a 8, donde 0 representa el mes de enero, 1 febrero, y así sucesivamente hasta 8, que representa septiembre
- $V(i,j,k)$ el conjunto de valores de Chl-a válidos para la posición (i,j) acumulados en k meses

$$V(i, j, k) = \{I_{m_{k-1}}, I_{m_{k-2}}, \dots, I_{m_0}\} \quad (1)$$

Donde:

$$k = \max\left\{n \mid M_{m_n} = 1, \forall n \in \{0, 1, \dots, k-1\}\right\} \text{ y } k \geq 2 \quad (2)$$

Los conjuntos de datos Dk se definen en la [Ecuación \(3\)](#) como.

Sean:

- Dk el conjunto de posiciones (i,j) donde existen k meses consecutivos con valores válidos de Chl-a
- $V(i,j,k)$ el conjunto de valores de Chl-a acumulados para la posición (i,j) en los k meses previos, tal como se define en la [Ecuación \(1\)](#)

$$Dk = \{(i, j) \mid V(i, j, k)\} \quad (3)$$

Para cada posición (i,j) en las imágenes, se acumulan los valores de Chl-a de los meses anteriores, siempre que la máscara de nubes permita valores válidos. Por ejemplo, si se tienen datos válidos para los meses de junio, julio y agosto, los respectivos valores se toman como la entrada del modelo. No se suman, sino que se tratan como características temporales adicionales que permiten realizar una predicción más precisa del valor en el mes objetivo (e.g., septiembre). Esto permite que el modelo analice cómo varían los valores de Chl-a a lo largo del tiempo sin sobreestimar el valor actual. Si se encuentran al menos dos meses consecutivos con datos válidos, los valores se guardan en el conjunto de datos correspondiente D_k , donde k indica el número de meses consecutivos con datos válidos. Los conjuntos de datos finales son la unión de todos los valores $V(i,j,k)$ obtenidos para cada k en todas las posiciones (i,j) de las imágenes.

Una vez generados los conjuntos de datos, se procedió al entrenamiento de modelos de aprendizaje profundo. Para el conjunto de datos más pequeño, correspondiente a tres meses consecutivos, se desarrolló y entrenó un modelo de red neuronal profunda. Para los otros dos conjuntos de datos, se implementó un proceso de búsqueda de hiperparámetros. En lugar de utilizar una única configuración de modelo, se probaron múltiples combinaciones de parámetros clave como el número de neuronas en cada capa, la tasa de aprendizaje y la tasa de *dropout*. Este enfoque permitió identificar la mejor configuración para cada conjunto de datos. El proceso incluyó la creación de modelos con capas similares a las descritas anteriormente, pero con variaciones en el número de neuronas y la tasa de *dropout* según los hiperparámetros específicos. Cada modelo fue entrenado y evaluado, y los resultados se compararon para seleccionar la mejor configuración.

Después de obtenerlos, los modelos se guardaron en formato pth, en aras de usarlos para predecir una nueva imagen de forma temporal. Esto se hace de la siguiente manera: se toman como entrada los valores de Chl-a de los tres meses anteriores y se produce una predicción para cada píxel en la imagen. La función matemática presentada a continuación describe un ejemplo con agosto como mes objetivo, considerando los tres meses inmediatamente anteriores (i.e., julio, junio y mayo). La [Ecuación \(4\)](#) expresa el proceso:

Sean:

- $P(i,j)$ el valor de Chl-a predicho en la posición (i,j) para el mes de agosto
- $T_{target}(i,j)$ el valor de Chl-a observado en la posición (i,j) para el mes de agosto (puede ser 0.0 si el píxel está nublado)
- $T_{july}(i,j)$ el valor de Chl-a en la posición (i,j) para el mes de julio
- $T_{june}(i,j)$ el valor de Chl-a en la posición (i,j) para el mes de junio
- $T_{may}(i,j)$ el valor de Chl-a en la posición (i,j) para el mes de mayo
- M_k el modelo de predicción entrenado con k características:
 - M3: modelo con tres entradas (mayo, junio y julio)
 - M2: modelo con dos entradas (junio y julio)
 - M1: Modelo con 1 entrada (solo julio).

$$P(i,j) = \begin{cases} T_{target}(i,j) & \text{si } T_{target}(i,j) \neq 0,0, \\ M_3(T_{may}(i,j), T_{june}(i,j), T_{july}(i,j)) & \text{si } T_{may}(i,j) \neq 0.0, T_{june}(i,j) \neq 0.0, T_{july}(i,j) \neq 0.0, \\ M_2(T_{june}(i,j), T_{july}(i,j)) & \text{si } T_{june}(i,j) \neq 0.0, T_{july}(i,j) \neq 0.0, T_{may}(i,j) = 0.0 \\ M_1(T_{july}(i,j)) & \text{si } T_{july}(i,j) \neq 0.0, T_{june}(i,j) = 0.0, T_{may}(i,j) = 0.0 \\ 0.0 & \text{en cualquier caso} \end{cases} \quad (4)$$

Se pueden dar varios casos, e.g., que el píxel sí tenga información. Si los valores de los tres meses anteriores son diferentes de 0.0, se aplica el modelo de tres entradas para predecir el píxel de agosto. Ocurre lo mismo si solo hay información en julio y junio y, si ningún mes tiene valores válidos, el resultado es 0.0. La [Figura 4](#) presenta un ejemplo de la conformación temporal de una imagen con información de tres meses anteriores.

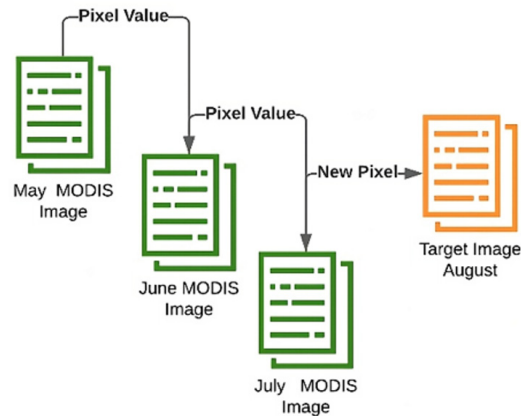


Figura 4. Representación de la conformación de una imagen a predecir de forma temporal

RESULTADOS

Los resultados obtenidos a partir de la metodología implementada en este estudio revelan una serie de hallazgos significativos en la predicción de valores de Chl-a. El proceso comenzó con la recopilación de imágenes satelitales MODIS para el periodo 2000-2023, por lo cual se obtuvieron 250 imágenes. Para cada mes dentro de este periodo, se seleccionó el primer día como referencia, *i.e.*, el primer día hábil de cada mes, con una resolución temporal de un mes. Cada imagen fue alineada espacialmente con el área de interés seleccionada, obteniendo una total de 519 593 píxeles en todas las imágenes. Estas imágenes fueron organizadas en grupos anuales que abarcaron periodos de nueve meses consecutivos. Para cada año, se formaron cuatro grupos de nueve imágenes, las cuales fueron corregistradas y procesadas para la generación de conjuntos de datos.

Una vez obtenidos los conjuntos de datos anuales, se procedió a fusionar los grupos de datos que compartían el mismo número de características temporales. Esto dio lugar a tres conjuntos de datos principales, cada uno correspondiente a un intervalo temporal distinto: el primero incluía valores de Chl-a válidos para un solo mes, el segundo abarcaba dos meses consecutivos y el tercero cubría tres meses consecutivos. En este contexto, los *registros* se refieren a observaciones válidas de Chl-a en los píxeles de las imágenes satelitales. El conjunto de datos para un mes contenía 287 554 registros, lo que representa los píxeles con datos válidos en ese periodo. Para el conjunto de dos meses consecutivos, se obtuvieron 27 400 registros, mientras que el conjunto de tres meses consecutivos incluyó 496 registros. Esto refleja una disminución en el número de observaciones válidas debido a la acumulación de imágenes afectadas por nubosidad.

Con los conjuntos de datos generados, se procedió a la etapa de entrenamiento de los modelos de aprendizaje profundo. Para el conjunto de datos más pequeño, correspondiente a tres meses consecutivos, se desarrolló un modelo de red neuronal profunda. Este modelo consistía en múltiples capas con un

número decreciente de neuronas, comenzando con 512 neuronas en la primera capa y reduciéndose hasta 32 neuronas en la última capa antes de la salida. En cada capa se utilizó una función de activación *Leaky ReLU*, y se aplicó la técnica de regularización de *dropout* con una tasa de 0.3 para prevenir el sobreajuste del modelo. El modelo fue entrenado durante 65 épocas, logrando un coeficiente de determinación (R^2) de 0.9138 y un error cuadrático medio de la raíz (RMSE) de 0.1111, lo cual indica un ajuste altamente preciso para este conjunto de datos. Para los conjuntos de datos restantes, correspondientes a uno y dos meses consecutivos, se llevó a cabo un proceso de búsqueda de hiperparámetros, en aras de optimizar el rendimiento de los modelos. En lugar de utilizar una única configuración, se probaron múltiples combinaciones de parámetros, incluyendo el número de neuronas por capa, la tasa de aprendizaje y la tasa de *dropout*. Esta estrategia permitió identificar las mejores configuraciones para cada conjunto de datos. El modelo optimizado para el conjunto de datos de dos meses consecutivos alcanzó un R^2 de 0.7967 y un RMSE de 0.3872, mientras que el modelo correspondiente a un mes consecutivo obtuvo un R^2 de 0.7017 y un RMSE de 0.3104.

Una vez entrenados los modelos de aprendizaje profundo, se procedió a probar su rendimiento utilizando el módulo Tester. Este módulo fue diseñado para evaluar la precisión de los modelos entrenados al aplicarlos a nuevas imágenes satelitales y verificar la calidad de las predicciones generadas. El código del presente trabajo, en el cual se desarrollan todos los módulos, se puede encontrar en la lista de referencias (Luis-Xmart/Framework, s.f.). Para el procesamiento de los datos de concentración de Chl-a, fue necesario normalizar los valores en un rango de 0 a 1, con el fin de facilitar el entrenamiento de los modelos de aprendizaje profundo y evitar que los valores más altos afectaran el desempeño del modelo. Además, se aplicaron técnicas de regularización L2, en aras de prevenir el sobreajuste y mejorar la capacidad del modelo para generalizar en nuevos datos.

Arquitectura de los modelos

Para la prueba, se cargaron dos arquitecturas diferentes de redes neuronales profundas, adaptadas según la cantidad de características temporales disponibles:

- **DeepNN3.** Este modelo fue diseñado para manejar tres características, lo que implica que tiene en cuenta los valores de Chl-a para los tres meses anteriores a la fecha objetivo. Esta arquitectura es más compleja, con cinco capas completamente conectadas, comenzando con 512 neuronas y reduciéndose progresivamente hasta 32 en la última capa antes de la salida. Este modelo es el más robusto y debería proporcionar las predicciones más precisas, pues se basa en la mayor cantidad de información temporal disponible.
- **DeepNN12.** Esta arquitectura fue utilizada para los conjuntos de datos con una o dos características temporales, es decir, cuando solo se dispone de los valores de Chl-a para uno o dos meses anteriores. Este modelo es más simple, con tres capas totalmente conectadas que van desde 512 neuronas en la primera capa hasta 128 en la última capa antes de la salida.

Las imágenes de prueba correspondientes a los meses de mayo a agosto fueron cargadas en el módulo Tester, donde se aplicaron los modelos entrenados. El resultado fue una nueva imagen que contenía los valores de Chl-a estimados por los modelos para el área de interés. En este punto se compararon las imágenes originales y las generadas por los modelos. Esta comparación se cuantificó mediante el cálculo de la media y la desviación estándar entre los valores de las dos imágenes.

Media de diferencias

La media entre las imágenes originales y predichas fue de 0.0315. Este valor representa el promedio de las diferencias entre los valores de Chl-a en cada píxel de las dos imágenes. Una media cercana a 0 indicaría que, en promedio, las predicciones están muy cerca de los valores reales. En este caso, la media de 0.0315 sugiere que, en promedio, las predicciones difieren ligeramente de los valores observados, lo cual es un buen indicador de precisión en las predicciones del modelo.

Desviación estándar de diferencias

La desviación estándar fue de 0.1580. Este valor mide la dispersión de las diferencias entre las imágenes originales y predichas. Una desviación estándar baja indicaría que dichas diferencias son consistentemente pequeñas en todos los píxeles, lo que significa que el modelo predice con precisión y de manera uniforme. Una desviación estándar de 0.1580 indica que, aunque las predicciones son en promedio cercanas a los valores reales (como lo sugiere la media), hay cierta variabilidad en la precisión del modelo para diferentes píxeles. Los resultados sugieren que los modelos entrenados, especialmente el DeepNN3, ofrecen una predicción razonablemente precisa de los valores de Chl-a, considerando la baja media de las diferencias. La desviación estándar moderada indica que, aunque en general las predicciones son acertadas, existe alguna variabilidad en la precisión a lo largo de la imagen. Esto podría estar relacionado con la naturaleza heterogénea de las condiciones ambientales de la región estudiada, o bien con limitaciones inherentes al modelo, dada la cantidad de datos disponibles para el entrenamiento. La [Figura 5](#) compara una imagen original del primero de agosto del 2020 con su respectiva predicción.

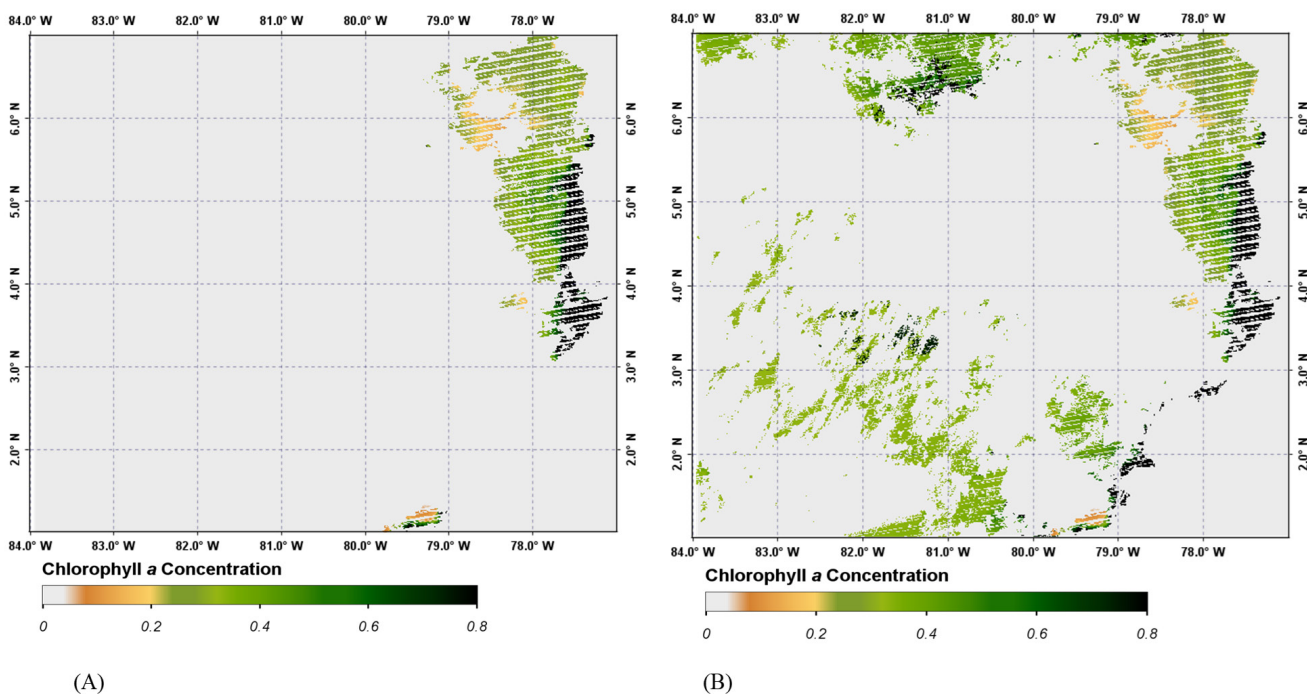


Figura 5. (a) Imagen original del mes de agosto de 2020, (b) resultado de predecir los valores de Chl-a con la metodología propuesta

CONCLUSIONES

Los modelos de aprendizaje profundo desarrollados en este estudio demostraron una alta precisión en la predicción de los valores de Chl-a. Particularmente, el modelo DeepNN3, entrenado con datos correspondientes a tres meses consecutivos, mostró un excelente rendimiento, con un R^2 de 0.9138 y un RMSE de 11% mg/m^3 . Estos resultados reflejan la capacidad del modelo para capturar la variabilidad presente de los datos con gran exactitud, lo que sugiere que, cuando se dispone de una mayor cantidad de información temporal, el modelo puede generar predicciones más precisas. Esta investigación demostró que la inclusión de datos temporales adicionales mejora significativamente la capacidad predictiva de los modelos de aprendizaje profundo. El DeepNN3 superó en precisión a los modelos que utilizaron solo uno o dos meses de datos (DeepNN12). Esto subraya la importancia de incorporar una mayor cantidad de características temporales en los estudios de teledetección para mejorar la exactitud de las predicciones y capturar con mayor fidelidad las dinámicas ambientales de la región estudiada. La media de las diferencias entre las imágenes originales y las generadas por los modelos (0.0315) sugiere que las predicciones son, en general, bastante precisas. Este resultado es alentador, pues demuestra que los modelos desarrollados pueden aplicarse en escenarios donde los datos observacionales de Chl-a sean limitados o incompletos. La capacidad de generar predicciones precisas con datos parciales resalta el potencial de estos modelos para su uso en el monitoreo y la gestión ambientales, especialmente en áreas con limitaciones de acceso a datos observacionales completos. En el futuro, los estudios podrían enfocarse en desarrollar modelos más robustos que capturen con mayor exactitud las condiciones heterogéneas de la Costa Pacífica colombiana, reduciendo así la variabilidad y mejorando la fiabilidad de las predicciones en diferentes contextos ambientales.

Contribución de autoría:

Luis-Miguel Martínez-Vargas: Conceptualización; metodología; *software*; validación; análisis formal; redacción-borrador original; redacción-revisión y edición.

Julián-Fernando Muñoz-Ordóñez: Conceptualización; metodología; *software*; validación; análisis formal; redacción-revisión y edición

Yady-Tatiana Solano-Correa: Conceptualización; metodología; redacción-borrador original; redacción-revisión y edición.

AGRADECIMIENTOS

Esta investigación recibió el apoyo del proyecto *Jóvenes investigadores e innovadores del departamento del Cauca*. Los autores también expresan sus agradecimientos a Miguel Diego Gómez Sánchez y Cristian Camilo Muñoz Ordóñez por sus valiosas asesorías y aportes a la investigación, y a la Corporación Universitaria Comfacauca (Unicomfacauca), a la Universidad del Cauca, al Centro de Investigaciones Oceanográficas e Hidrográficas del Caribe (CIOH) y al Centro de Investigaciones Oceanográficas e Hidrográficas del Pacífico (CCCCP) por su apoyo durante el desarrollo de este trabajo.

REFERENCIAS

- Abbas, M. M., Melesse, A. M., Scinto, L. J., Rehage, J. S. (2019). Satellite estimation of chlorophyll-a using moderate resolution imaging spectroradiometer (MODIS) sensor in shallow coastal water bodies: Validation and improvement. *Water*, 11(8), 1621. <https://doi.org/10.3390/W11081621>
- Barazzetti, L., Scaioni, M., Gianinetto, M. (2014). Automatic co-registration of satellite time series via least squares adjustment. *European Journal of Remote Sensing*, 47(1), 55-74. <https://doi.org/10.5721/EuJRS20144705>
- Baudena, A., Ser-Giacomi, E., D'Onofrio, D., Capet, X., Cotté, C., Cherel, Y., D'Ovidio, F. (2021). Fine-scale structures as spots of increased fish concentration in the open ocean. *Scientific Reports*, 11(1), 1-13. <https://doi.org/10.1038/s41598-021-94368-1>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324/METRICS>
- Chen, S., Deng, L., Zhao, J. (2024). Enhanced reconstruction of satellite-derived monthly chlorophyll a concentration with fourier transform convolutional-LSTM. *IEEE Transactions on Geoscience and Remote Sensing*, 62, 1-14. <https://doi.org/10.1109/TGRS.2024.3394399>
- Cho, H., Park, H. (2019). Merged-LSTM and multistep prediction of daily chlorophyll-a concentration for algal bloom forecast. *IOP Conference Series: Earth and Environmental Science*, 351(1), 012020. <https://doi.org/10.1088/1755-1315/351/1/012020>
- Chuvieco Salinero, E. (2002). *Teledetección ambiental: la observación de la tierra desde el espacio*. Ariel.
- Dash, A., Jetley, S., Rege, A., Chopra, S., Sawant, R. (2022). *Drought prediction and water quality estimation using satellite images and machine learning* [Artículo de conferencia]. 7th International Conference on Communication and Electronics Systems, ICCES 2022, India. <https://doi.org/10.1109/ICCES54183.2022.9835727>
- Du, Z., Wu, S., Kwan, M. P., Zhang, C., Zhang, F., Liu, R. (2018). A spatiotemporal regression-kriging model for space-time interpolation: A case study of chlorophyll-a prediction in the coastal areas of Zhejiang, China. *International Journal of Geographical Information Science*, 32(10), 1927-1947. <https://doi.org/10.1080/13658816.2018.1471607>
- Essien, P., Figueiredo, C. A. O. B., Takahashi, H., Klutse, N. A. B., Wrasse, C. M., Afonso, J. M. de S., Quispe, D. P., Lomotey, S. O., Ayorinde, T. T., Sobral, J. H. A., Eghan, M. J., Sackey, S. S., Barros, D., Bilibio, A. V., Nkrumah, F., Quagraine, K. A. (2022). Intertropical convergence zone as the possible source mechanism for southward propagating medium-scale traveling ionospheric disturbances over South American low-latitude and equatorial region. *Atmosphere*, 13(11), e1836. <https://doi.org/10.3390/ATMOS13111836>
- Eze, E., Kirby, S., Attridge, J., Ajmal, T. (2021). Time series chlorophyll-a concentration data analysis: A novel forecasting model for aquaculture industry. *Engineering Proceedings*, 5(1), e27. <https://doi.org/10.3390/ENGPROC2021005027>
- Hänninen, J., Mäkinen, K., Nordhausen, K., Laaksonlaita, J., Loisa, O., Virta, J. (2022). The "Seili-index" for the prediction of chlorophyll- α levels in the archipelago sea of the northern Baltic Sea, southwest Finland. *Environmental Modeling & Assessment*, 27, 571-584. <https://doi.org/10.1007/s10666-022-09822-9>
- Hu, H., Fu, X., Li, H., Wang, F., Duan, W., Zhang, L., Liu, M. (2023). Prediction of lake chlorophyll concentration using the BP neural network and Sentinel-2 images based on time features. *Water Science and Technology*, 87(3), 539-554. <https://doi.org/10.2166/WST.2023.019>
- Li, X., Sha, J., Wang, Z. L. (2018). Application of feature selection and regression models for chlorophyll-a prediction in a shallow lake. *Environmental Science and Pollution Research*, 25(20), 19488-19498. <https://doi.org/10.1007/S11356-018-2147-3/METRICS>
- Luis-xmart/framework (s.f.). <https://gitfront.io/r/Luis-xmart/3nDgRRysh6j3/framework-chl-temp/>

- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Nascimento Silva, H. A., Rosato, A., Altilio, R., Panella, M. (2018). *Water quality prediction based on wavelet neural networks and remote sensing* [Artículo de conferencia]. International Joint Conference on Neural Networks, Rio de Janeiro, Brasil. <https://doi.org/10.1109/IJCNN.2018.8489662>
- Papenfus, M., Schaeffer, B., Pollard, A. I., Loftin, K. (2020). Exploring the potential value of satellite remote sensing to monitor chlorophyll-a for US lakes and reservoirs. *Environmental Monitoring and Assessment*, 192(12), 1-22. <https://doi.org/10.1007/S10661-020-08631-5>
- Park, Y., Cho, K. H., Park, J., Cha, S. M., Kim, J. H. (2015). Development of early-warning protocol for predicting chlorophyll-a concentration using machine learning models in freshwater and estuarine reservoirs, Korea. *Science of the Total Environment*, 502, 31-41. <https://doi.org/10.1016/j.scitotenv.2014.09.005>
- Poddar, S., Chacko, N., Swain, D. (2019). Estimation of chlorophyll-a in northern coastal bay of Bengal using Landsat-8 OLI and Sentinel-2 MSI sensors. *Frontiers in Marine Science*, 6, e00598. <https://doi.org/10.3389/fmars.2019.00598>
- Salomonson, V. V., Barnes, W., Masuoka, E. J. (2006). Introduction to MODIS and an overview of associated activities. *Earth Science Satellite Remote Sensing: Science and Instruments*, 1, 12-32. https://doi.org/10.1007/978-3-540-37293-6_2
- Shin, Y., Kim, T., Hong, S., Lee, S., Lee, E., Hong, S. W., Lee, C. S., Kim, T. Y., Park, M. S., Park, J., Heo, T. Y. (2020). Prediction of chlorophyll-a concentrations in the Nakdong River using machine learning methods. *Water*, 12(6), 1822. <https://doi.org/10.3390/w12061822>
- Silveira Kupssinskü, L., Thomassim Guimarães, T., Menezes de Souza, E., C. Zanotta, D., Roberto Veronez, M., Gonzaga, L., Mauad, F. F. (2020). A method for chlorophyll-a and suspended solids prediction through remote sensing and machine learning. *Sensors*, 20(7), e2125. <https://doi.org/10.3390/s20072125>
- Stramska, M., Jakacki, J. (2024). Variability of chlorophyll a concentration in surface waters of the open Baltic Sea. *Oceanologia*, 66(2), 365-380. <https://doi.org/10.1016/j.oceano.2024.02.003>
- Wang, G., Hao, J., Ma, J., Jiang, H. (2011). A comparative assessment of ensemble learning for credit scoring. *Expert Systems with Applications*, 38(1), 223-230. <https://doi.org/10.1016/j.eswa.2010.06.048>
- Wang, H., Yan, X., Chen, H., Chen, C., Guo, M. (2015). Chlorophyll-a predicting model based on dynamic neural network. *Applied Artificial Intelligence*, 29(10), 962-978. <https://doi.org/10.1080/08839514.2015.1097142>
- Wilson, A. M., Jetz, W. (2016). Remotely sensed high-resolution global cloud dynamics for predicting ecosystem and biodiversity distributions. *PLOS Biology*, 14(3), e1002415. <https://doi.org/10.1371/JOURNAL.PBIO.1002415>
- Yajima, H., Derot, J. (2018). Application of the Random Forest model for chlorophyll-a forecasts in fresh and brackish water bodies in Japan, using multivariate long-term databases. *Journal of Hydroinformatics*, 20(1), 191-205. <https://doi.org/10.2166/HYDRO.2017.010>
- Yu, X., Shen, J., Zheng, G., Du, J. (2022). Chlorophyll-a in Chesapeake Bay based on VIIRS satellite data: Spatiotemporal variability and prediction with machine learning. *Ocean Modelling*, 180, e102119. <https://doi.org/10.1016/j.ocemod.2022.102119>

