

INSTITUTO TECNOLÓGICO DE COSTA RICA  
ESCUELA DE QUÍMICA  
CARRERA DE INGENIERÍA AMBIENTAL

Proyecto Final de Graduación para optar por el grado de Licenciatura en Ingeniería  
Ambiental

**Modelaje de modificaciones en clorofila-a y sólidos suspendidos totales del río  
Sierpe con bases de datos multiespectrales**

Gabriela Chaves Brenes

CARTAGO, agosto, 2022

**TEC** | Tecnológico de Costa Rica  
Ingeniería Ambiental

**“Modelaje de modificaciones en clorofila-a y sólidos suspendidos totales del río Sierpe con bases de datos multiespectrales”**

Informe presentado a la Escuela de Química del Instituto Tecnológico de Costa Rica como requisito parcial para optar por el título de Ingeniero Ambiental con el grado de licenciatura

**Miembros del tribunal**

---

**MSc. Laura Hernández Alpízar**  
**Directora**

---

**MSc. Iván Ávila Pérez**  
**Lector 1**

---

**MSc. Diana Alejandra Zambrano Piamba**  
**Lector 2**

---

**Dra. ir. Mary Luz Barrios Hernández**  
**Coordinadora COTRAFIG**

---

**M.G.A. Ricardo Coy Herrera**  
**Director Escuela de Química**

---

**MSc. Diana Alejandra Zambrano Piamba**  
**Coordinadora Carrera de Ingeniería Ambiental**

*A mami, Mariah y Karla*

## AGRADECIMIENTOS

Quiero agradecer profundamente a mi familia, que no solo han sido maestras de profesión, sino maestras en mi vida. Agradezco especialmente a tía Tere por sus consejos y la revisión filológica. A mi madre y a mi hermana, que han sido mis pilares toda mi vida. Su amor incondicional, compañía y apoyo han sido indispensables para culminar este proceso. A Karla, que se convirtió en mi familia durante mi etapa universitaria y cuyo apoyo también fue determinante en esta etapa final.

A Isenny, Esteban y Valeria, que más que compañeros de estudio fueron amigos y consejeros durante toda la carrera. Su apoyo en todos los cursos que compartimos me permitió llegar hasta el final.

A la profe Laura, por ser mi tutora en esta tesis, pero más allá de eso por compartir su conocimiento, su mente innovadora y su pasión por los temas ambientales. Por permitirme participar en proyectos y asistencias que ampliaron mis capacidades para convertirme en ingeniera ambiental. Igualmente a todos los profesores que fueron parte de mi formación.

Al Laboratorio PRIAS del CeNAT, por darme la oportunidad de ser pasante durante este proyecto. Especialmente al ingeniero Iván Ávila, por las enseñanzas en temas de teledetección y el acompañamiento durante el desarrollo del proyecto.

Al TEC que, como institución pública, me permitió el acceso a una carrera tecnológica como Ingeniería Ambiental.

## TABLA DE CONTENIDO

<b>Resumen</b>	<b>viii</b>
<b>Abstract</b>	<b>x</b>
<b>1. Introducción</b>	<b>11</b>
<b>2. Objetivos</b>	<b>13</b>
<i>Objetivo general</i>	<i>13</i>
<i>Objetivos específicos</i>	<i>13</i>
<b>3. Marco teórico</b>	<b>14</b>
3.1 <i>Uso de agroquímicos en Costa Rica</i>	<i>14</i>
3.2 <i>Consecuencias de las actividades humanas en los humedales</i>	<i>15</i>
3.3 <i>Impacto en el río Sierpe</i>	<i>16</i>
3.4 <i>Calidad del agua</i>	<i>17</i>
3.5 <i>Disponibilidad de datos e información</i>	<i>18</i>
3.6 <i>Teledetección</i>	<i>19</i>
3.6.1 <i>Sensores óptico-electrónicos</i>	<i>20</i>
3.6.1.1 <i>Landsat 8</i>	<i>22</i>
3.6.1.2 <i>Sentinel 2</i>	<i>23</i>
3.7 <i>Google Earth Engine</i>	<i>25</i>
<b>3.8 Transformación de imágenes</b>	<b>26</b>
<b>3.9 Objetivos de Desarrollo Sostenible</b>	<b>28</b>
<b>4. Metodología</b>	<b>30</b>
4.1 <i>Lugar de estudio</i>	<i>30</i>
4.2 <i>Datos de validación</i>	<i>31</i>
4.3 <i>Procesamiento de imágenes satelitales en GEE</i>	<i>32</i>
<b>5. Resultados y discusión</b>	<b>36</b>
5.1 <i>Clorofila-a</i>	<i>36</i>
5.1.1 <i>Validación de clorofila-a</i>	<i>36</i>
5.1.2 <i>Modelos de clorofila-a</i>	<i>37</i>

5.2	<i>SST</i>	43
5.2.1	Validación de SST	43
5.2.2	Modelos de SST	44
5.3	<i>Observación de modificaciones</i>	49
<b>6.</b>	<b>Conclusiones y recomendaciones</b>	<b>51</b>
6.1	<i>Conclusiones</i>	51
6.2	<i>Recomendaciones</i>	52
<b>7.</b>	<b>Referencias</b>	<b>53</b>
<b>8.</b>	<b>Anexos</b>	<b>57</b>
8.1	<i>Anexo 1: Código utilizado para el modelaje de Clorofila-a</i>	57
8.1.1	Enlace al código	64
8.2	<i>Anexo 2: Código utilizado para el modelaje de SST</i>	64
8.2.1	Enlace al código de SST	75

## LISTA DE FIGURAS

Figura 1. Índice WET de la estimación de pérdidas de humedales tierra adentro y marino costeros. Adaptado de [2]. .....	15
Figura 2. Mapa de uso de suelo alrededor del Humedal Nacional Terraba Sierpe [18].....	16
Figura 3. Espectro electromagnético [28].....	20
Figura 4. Representación gráfica de la combinación de bandas representadas en los tonos rojo, verde y azul [42].....	27
Figura 5. Ubicación del Río Sierpe en la zona sur de Costa Rica. Elaboración propia.....	30
Figura 6. Distribución espaciotemporal de las campañas de muestreo en el río Sierpe. Elaboración propia.....	31
Figura 7. Diagrama de flujo del proceso para la determinación de los parámetros clorofila-a y SST por medio de imágenes satelitales procesadas en GEE. Adaptado de Ruíz Ramírez [45] .....	35
Figura 8. Gráfico de dispersión para comparar el comportamiento de los datos de concentración generados por el modelo (5) con los datos de laboratorio .....	37
Figura 9. Modelación de clorofila para los días coincidentes con las fechas de muestreo: a. 07/03/2019, b. 12/03/2019, c. 27/03/2019.....	39
Figura 10. Modelación de clorofila para los días coincidentes con las fechas de muestreo: a. 22/11/2019, b. 27/11/2019, c. 02/12/2019.....	41
Figura 11. Modelación de clorofila coincidente con fechas de muestreo de marzo 2021 ....	42
Figura 12. Gráfico de dispersión para comparar el comportamiento de los datos de concentración generados por el modelo (5) con los datos de laboratorio .....	44
Figura 13. Modelación de SST para los días coincidentes con las fechas de muestreo: a. 07/03/2019, b. al 12/03/2019, c. 27/03/2019.....	45
Figura 14. Modelación de SST para los días coincidentes con las fechas de muestreo: a. 22/11/2019, b. 27/11/2019, c. 02/12/2019.....	47
Figura 15. Modelación de SST coincidente con fechas de muestreo de marzo 2021 .....	48
Figura 16. Modelaje de clorofila para el mes de julio del 2019 .....	50

## **LISTA DE CUADROS**

Cuadro 1. Resumen de satélites con cualidades para evaluar agua superficial [32] .....	21
Cuadro 2. Rangos de frecuencia del espectro electromagnético y resolución espacial de los sensores OLI y TIRS del satélite Landsat 8 [35].....	23
Cuadro 3. Longitud de onda central, ancho de bandas y resolución espacial de las bandas del sensor MSI de los satélites Sentinel-2A y Sentinel-2B [38] .....	24
Cuadro 4. Resumen de metas asociadas a los ODS de la Agenda 2030 cuyo progreso se puede monitorear con herramientas de teledetección [48].....	29

## LISTA DE SIGLAS Y ACRÓNIMOS

API	Application Programming Interface
BOA	Bottom of the Atmosphere
CeNAT	Centro Nacional de Alta Tecnología
EPA	Environmental Protection Agency
ESA	European Space Agency
FAO	Food and Agriculture Organization
GEE	Google Earth Engine
GMES	Global Monitoring for Environmental Security
HNTS	Humedal Nacional Térraba Sierpe
IDE	Integrated Development Environment
MINAE	Ministerio de Ambiente y Energía
MSI	Multispectral Instrument
NASA	National Aeronautics and Space Administration
NIR	Near Infrared
NOAA	National Oceanic and Atmospheric Administration
OCDE	Organización para la Cooperación y el Desarrollo Económicos
ODS	Objetivos de Desarrollo Sostenible
OLI	Operational Land Imager
PNUD	Programa de las Naciones Unidas para el Desarrollo
SINAC	Sistema Nacional de Areas de Conservación
SST	Sólidos Suspendidos Totales
TIRS	Thermal Infrared Sensor
TOA	Top of the Atmosphere
USGS	United States Geological Survey
WET	Wetland Extent Trends Index

## Resumen

Mediante el uso de Google Earth Engine (GEE), plataforma diseñada para el procesamiento de bases de datos espectrales satelitales y observación temporal de fenómenos terrestres, se probaron dos modelos de correlación de bandas espectrales para la determinación de clorofila-a y sólidos suspendidos totales (SST) en el río Sierpe, ubicado dentro del Humedal Nacional Terraba Sierpe (HNNTS), Costa Rica. En este río se han observado impactos relacionados con el uso de fertilizantes de la agricultura extensiva que le rodea. La poca disponibilidad de datos en sistemas tan amplios, unida a la relevancia ambiental de los humedales en la calidad hídrica, determina la necesidad de probar técnicas de observación de tendencia o modificaciones en el tiempo de bajo costo y que abarquen grandes territorios, para la gestión adecuada de las actividades humanas. El uso de datos satelitales para modelación y observación ha sido muy útil en condiciones atmosféricas de zonas templadas, pero presenta un reto para su uso en condiciones climáticas tropicales que muestran abundante nubosidad y donde existe aún poca experimentación en el ajuste de funciones de correlación. En este trabajo se investigaron las opciones de modelación con funciones de correlación de bandas espectrales más apropiadas para condiciones tropicales y se implementaron en una rutina de análisis territorial de datos espectrales para el río Sierpe. Los resultados obtenidos del modelaje se compararon con datos de laboratorio provistos por el proyecto MONEO (*Monitoring the Neotropical Environment through Earth Observation*), del Laboratorio PRIAS. Se generaron gráficos de dispersión para visualizar el comportamiento de las concentraciones de campo y las concentraciones obtenidas con las funciones de correlación. Se generaron 43 imágenes por cada modelo, de las cuales se tomaron las más cercanas a las fechas de los muestreos para la validación. Los resultados mostraron un error variable de acuerdo con la fórmula de correlación utilizada, pero significativo en la predicción de la magnitud de la concentración, sin embargo a nivel de tendencia del comportamiento territorial en los diferentes periodos se obtuvo una buena correspondencia para ambos modelos. Se concluye que la principal razón por la obtención de errores altos se debe a la corrección atmosférica de las imágenes *Bottom of the Atmosphere* (BOA) de Sentinel-2, que aún requiere ajustes para condiciones tropicales y aguas continentales. Aun así, se demuestra la aplicabilidad de la observación de modificaciones con datos satelitales para comportamientos cualitativos generales de ríos a nivel territorial.

**Palabras clave:** modelaje, Google Earth Engine, clorofila-a, sólidos suspendidos totales

## **Abstract**

Using Google Earth Engine (GEE), a platform designed for the processing of satellite spectral databases and temporal observation of terrestrial phenomena, two spectral band correlation models were tested for the determination of chlorophyll-a and total suspended solids (TSS) in the Sierpe River, located within the Térraba Sierpe National Wetland (HNNTS), Costa Rica. In this river, field data have shown the impacts related to the use of fertilizers from the extensive agriculture that surrounds it. The limited availability of data in such large systems and the environmental relevance of wetlands in water quality, determines the need to test low-cost techniques for observing trends in changes over time and covering large territories, for the proper management of human activities. The use of satellite data for modeling and observation has been very useful for atmospheric conditions in temperate zones, but it presents a challenge for its use in tropical climatic conditions that show abundant cloudiness and where there is still very little experimentation in the adjustment of correlation functions. In this work, the modeling options with the most appropriate spectral band correlation functions due to the similarity of tropical conditions were investigated and implemented in a territorial analysis routine of spectral data for the Sierpe River. The results obtained from the modeling were compared with laboratory data provided by the MONEO project of the PRIAS Laboratory. Scatter plots were generated to visualize the behavior of the field concentrations and the concentrations obtained with the correlation functions. Forty-three images were generated for each model, of which the closest to the sampling dates were taken for the validation discussion. The results showed a variable error according to the correlation formula used but very significant in the prediction of the magnitude of the concentration, however, at the level of the trend of the territorial behavior in the different periods, a good correspondence was obtained for both models. It is concluded that the main reason for obtaining high errors is due to the atmospheric correction applied to the Sentinel-2 Bottom of the Atmosphere (BOA) images, which still requires adjustments for tropical conditions and inland waters. Even so, the applicability of the observation of modifications with satellite data for general qualitative behavior of rivers at the territorial level is demonstrated.

**Key words:** modelling, Google Earth Engine, chlorophyll-a, total suspended solids

## 1. Introducción

Las cuencas hidrográficas son espacios delimitados por líneas de agua, que drenan y dirigen las precipitaciones y cuerpos de agua más pequeños a otros de mayor caudal, como acuíferos, lagos, ríos y océanos. Estas son una unidad básica para determinar si ha habido algún cambio ambiental pues su contenido describe el uso de tierra, bosque y recursos hídricos. Por otra parte, un cambio del uso de suelo con arrastre de contaminantes a lo largo de las cuencas hidrográficas puede generar cambios en los ecosistemas dentro de las cuencas [1].

Sin embargo, y a pesar de su importancia, existen vacíos considerables en la información y la evidencia base para evaluar su calidad, pues la cobertura de los indicadores se ha recopilado de forma desigual, especialmente en términos de área [2]. La razón principal de estas brechas en la información se debe al monitoreo inconsistente a nivel regional, insuficientes recursos humanos y financieros, además de la falta de consenso en qué monitorear. Una de las soluciones que se ha buscado para compensar la necesidad de datos es una red de observación global [3].

Google Earth Engine (GEE) es una herramienta desarrollada como plataforma de geoprocetamiento para el análisis geoespacial basado en el almacenamiento continuo de datos en la nube, con acceso libre a recursos computacionales de alto rendimiento. Se accede y se controla a través de una interfaz de programación de aplicaciones accesible a través de Internet (API), para Python o JavaScript con la finalidad de realizar peticiones a los servidores de GEE. Posee un entorno de desarrollo interactivo (IDE) asociado que permite la creación rápida de prototipos y la visualización de resultados [4]. Este software tiene acceso a bases de datos de programas satelitales como Landsat cuya base de datos es superior a 40 años de recopilación. Los datos que se obtienen son de reflectancia tanto en longitudes de onda visibles como no visibles. Por otro lado, también es posible cargar datos ráster y vectoriales propios [5].

Algunos parámetros de calidad del agua que se pueden analizar con esta herramienta son por ejemplo la turbidez, sólidos suspendidos, algas, microorganismos y clorofila,

parámetros que están relacionados con el impacto de actividades humanas como la eutrofización [6], proceso por el cuál un cuerpo de agua enriquecido con nutrientes experimenta un crecimiento de plantas acuáticas que agotan el oxígeno y alteran su ecosistema [7].

Este proyecto desarrolla la identificación de clorofila-a y material particulado mediante GEE, para observar modificaciones ambientales del Humedal Nacional Terraba Sierpe, particularmente en el Río Sierpe. Esta región está rodeada de actividades agrícolas con un uso intensivo de fertilizantes. Los humedales en general son ecosistemas que se impactan de forma negativa por las actividades antropogénicas. Según el índice WET, a nivel mundial las pérdidas de humedales marino-costeros alcanzan un 40% y en la zona del neotrópico no existen suficientes datos [2].

La identificación de modificaciones de calidad hídrica con datos espectrales ha sido probada en condiciones atmosféricas de baja nubosidad, sin embargo la metodología aún se encuentra en desarrollo en ambientes tropicales como los del HNTS, y esto es un aporte principal de este trabajo. Los datos más apropiados para este proyecto son los obtenidos por los satélites de observación terrestre Sentinel-2, que lleva a bordo el sensor MSI (*Multispectral Instrument*). Las imágenes poseen una resolución espacial de 10, 20 y 60 metros adecuada para la evaluación de cuerpos de agua y además una serie de bandas que pueden asociarse a vegetación y biomasa [8]. Con esta investigación se buscó además observar la evolución de la calidad del Río Sierpe, con el fin de contribuir a la conservación del humedal y aportar a la Política Nacional de Humedales.

## **2. Objetivos**

### **Objetivo general**

- Modelar modificaciones de clorofila-a y sólidos suspendidos totales en el río Sierpe con bases de datos multiespectrales

### **Objetivos específicos**

- Seleccionar la base de datos y las bandas óptimas relacionadas con clorofila-a y sólidos suspendidos totales.
- Modelar las funciones y visualizar los resultados.
- Validar los resultados con datos del sitio.

### **3. Marco teórico**

#### **3.1 Uso de agroquímicos en Costa Rica**

Desde hace 10 años Costa Rica empezó a ser tema de discusión por su consumo irracional de agroquímicos. En el año 2011, el país era el mayor consumidor de agroquímicos por unidad de área a nivel mundial. Esta situación colocó al país en una situación incómoda, pues era considerado líder en conservación del ambiente, sin embargo la demanda de estos productos para los cultivos extensivos provocó incidentes de contaminación química en fuentes de agua de consumo, provenientes de mantos acuíferos y las aguas superficiales, además de afectar directamente la salud de los obreros agrícolas, quienes tuvieron consecuencias como cáncer, esterilidad, abortos y malformaciones genéticas [9]. Entre los agroquímicos más utilizados destacan los fertilizantes, para el año 2010 Costa Rica era el mayor consumidor de fertilizantes entre los países de la Organización para la Cooperación y el Desarrollo Económicos (OCDE) [10].

Nueve años después de esas noticias la situación no es distinta, de acuerdo con el *Estado de la Nación* en los últimos cinco años se incrementó el uso de agroquímicos en un 37,2%, que se relaciona con el crecimiento del área sembrada y de producción. Este incremento se ha sostenido debido a la flexibilidad que el gobierno le ha otorgado al registro de agroquímicos, permitiendo que se mantengan los patrones de insostenibilidad [11]. En el caso específico de los fertilizantes nitrogenados, Costa Rica pasó de importar y utilizar 272.298,71 toneladas en el 2019 a 299.202,88 toneladas en el 2020. Un aumento de 9,88% en solo un año [12]. Estos fertilizantes se utilizan en la mayoría de los cultivos en Costa Rica, tales como café, arroz, palma aceitera y hortalizas. No obstante, no existe un control sobre la cantidad que se utiliza en cada cultivo, y es posible que se utilicen en exceso, poniendo en riesgo el suelo y el agua [10].

### 3.2 Consecuencias de las actividades humanas en los humedales

Diversos estudios demuestran que existen consecuencias negativas de los agroquímicos sobre ecosistemas como los humedales. En estos hábitats se dan una serie de procesos bióticos y abióticos que involucran temperatura, oxígeno, pH y salinidad. Los procesos abióticos influyen directamente en la liberación de nutrientes y por lo tanto en la actividad microbiana que se da en su interior; la cual favorece a su vez la eliminación de contaminantes [13]. Sin embargo, las acciones humanas como la agricultura intensiva en los alrededores de los humedales han provocado su degradación y el impedimento de cumplir con sus funciones depuradoras [14].

En general, las actividades humanas han provocado pérdidas en los humedales de 30% en los humedales tierra adentro y hasta 40% en los humedales marino-costeros (Figura 1). Los porcentajes de disminución al 2010 se calcularon mediante el primer indicador de cambio mundial en área de humedal natural el *Wetland Extent Trends Index* (WET), el cual utilizó otros índices de tendencias globales y datos, tanto localizados como teledetectados, en estudios a nivel mundial sobre evaluación y monitoreo de humedales, dando como resultado un índice para cada continente [2]. En el 2017 se realizó un estudio utilizando este mismo índice para todas las áreas Ramsar, los resultados mostraron que el declive en los humedales naturales prevalece y, por el contrario, los humedales artificiales incrementaron. El promedio anual de pérdidas de humedales es de -0,78%, una tasa tres veces más rápida que la pérdida de áreas de bosque [15].




Figura 1. Índice WET de la estimación de pérdidas de humedales tierra adentro y marino costeros. Adaptado de [2].

### 3.3 Impacto en el río Sierpe

El Río Sierpe se ubica en el cantón de Osa, recorre los distritos de Palmar, Sierpe y Puerto Cortés. Es parte del Humedal Nacional Térraba Sierpe y el sistema de humedales que forma ocupa un área de 9723,5 hectáreas, aproximadamente un 40% del HNTS [16]. Este es uno de los humedales más importantes de Costa Rica, en él confluye la cuenca más grande del país, y es el más grande a nivel centroamericano. El HNTS es un sitio Ramsar, lo que lo posiciona como un humedal de relevancia mundial, con lo que el país adquirió un compromiso internacional para velar por su resguardo. Es de tipo estuarino, caracterizado por incluir hábitats de aguas profundas y tierras con influencia marina [17].

A pesar de la relevancia de este humedal, el mismo se encuentra rodeado de actividades que lo impactan negativamente, como los poblados cercanos y los cultivos de arroz y palma africana que ocupan un área significativa (Figura 2). Todo lo anterior provoca la llegada de coliformes fecales, plaguicidas, herbicidas y fertilizantes nitrogenados. Estos pueden alcanzar el humedal por distintas vías, ya sea infiltración, escorrentía o incluso directamente mediante fumigaciones aéreas [18].




Figura 2. Mapa de uso de suelo alrededor del Humedal Nacional Térraba Sierpe [18]

Por otra parte, la Política Nacional de Humedales verificó el impacto actual de estos en el país, mediante un índice general compuesto de índices sociales, económicos y ambientales. Cada uno es calculado utilizando dimensiones, indicadores y variables por separado a nivel cantonal y posteriormente integrado a nivel de cuenca hidrográfica. Para obtener un índice global, los valores de los 4 índices se agrupan en 3 categorías de priorización de intervención por sus condiciones sociales, ambientales y económicas. De esta manera, un valor de 1 significa una prioridad baja, el valor de 2 una prioridad media y el 3 una prioridad alta [19].

En el río Sierpe se observan consecuencias derivadas del uso de fertilizantes en los cultivos de palma y arroz que le rodean, que al drenarse o arrastrarse por los canales de los cultivos de palma provocan un exceso de nitratos en esta zona protegida, con picos de concentración del ion nitrato después de los periodos de fertilización [20]. El panorama del Terraba-Sierpe no es alentador, sus condiciones socioeconómicas y ambientales lo ubican en la categoría 3, por lo que su intervención es urgente [19].

### **3.4 Calidad del agua**

Las prácticas agrícolas intensivas generan la degradación del humedal, ya que pueden provocar condiciones que ponen en riesgo el equilibrio ecosistémico. Un ejemplo es la eutrofización, definida como el proceso por el cual un cuerpo de agua se enriquece con nutrientes y estimula el crecimiento de las plantas acuáticas, que agotan el oxígeno disuelto cuando se degradan, generando baja concentración de este parámetro, usualmente menor a 2 ppm, lo que conlleva a condiciones hipóxicas. En los casos más severos pueden alcanzar condiciones de 0% de saturación de oxígeno, generando condiciones anóxicas [7]. En ambos casos se puede provocar la muerte masiva de especies acuáticas [21]. La eutrofización se relaciona con el aumento de sólidos suspendidos totales (SST) y materia coloidal, como arcilla, limo, materia orgánica e inorgánica y organismos microscópicos como el plancton, que provocan la disminución de la transmitancia de la luz a través del agua [6]. El cambio óptico que causan estos parámetros permite analizarlos remotamente, ya que los SST y la materia coloidal provocan turbidez en el agua, que suscita la absorción y dispersión de la luz.

De esta forma se puede inferir el estado de un cuerpo de agua, ya que la claridad es un determinante de su condición y productividad [22].

Los aumentos de eutrofización se comprobaron a partir de la segunda mitad del siglo XX. Tanto por nitrógeno, cuyo uso se ha incrementado drásticamente, como por fósforo, que incluso ha amplificado su ciclo en un 400%. Esto se atribuye a actividades de agricultura y quema de combustibles fósiles [23].

### **3.5 Disponibilidad de datos e información**

No hay suficiente información acerca de los cambios en área o en calidad de los humedales. Entre las causas se menciona que no se ha compartido información suficiente, que existe una falta de consenso sobre qué monitorear y de recursos económicos para un monitoreo integral. Aunque muchas organizaciones e iniciativas recolectan datos que pueden ser añadidos a una red de observación global, siguen existiendo muchos vacíos [3].

A pesar de la importancia de los servicios ambientales que proveen los humedales, no se tienen suficientes indicadores sobre su estado y evolución. En la zona del neotrópico los datos disponibles son insuficientes para crear índices robustos. Un ejemplo claro fue durante el cálculo del índice WET, mencionado anteriormente en la sección sobre consecuencias de las actividades humanas en los humedales. No fue posible representar un índice regional por la deficiente información en el neotrópico, por lo que urge la evaluación y monitoreo de los humedales en muchas áreas [2].

En el 2018 se hizo un inventario de los humedales en el país con el fin de satisfacer la falta de información. Para ello se utilizó información geoespacial y datos de campo. Este inventario ha servido como herramienta de protección y rehabilitación para el Sistema Nacional de Áreas de Conservación (SINAC) ante las amenazas que atentan contra los humedales. La base de datos incluye información sobre las condiciones de los humedales, tanto de las actividades que se dan en ellos y sus alrededores (drenajes, sedimentación, ganadería, agricultura y contaminación), como de su estado actual [17].

### **3.6 Teledetección**

La teledetección es una de las herramientas más discutidas en los artículos que tratan temas acerca de los vacíos de información de los humedales. Principalmente porque existen datos de la superficie terrestre recopilados por décadas y de acceso gratuito que pueden utilizarse para determinar el estado de los humedales, incluso los de más difícil acceso. Esto ahorraría los costos que generan las recurrentes visitas de campo que se requieren para obtener resultados relevantes. Entre las herramientas más utilizadas para la detección de datos espaciales se encuentran las imágenes ópticas obtenidas de sensores satelitales, fotografías aéreas de vehículos no tripulados y las imágenes de RADAR [24].

En síntesis, la teledetección se trata de la adquisición de información y datos de forma remota es decir sin estar en contacto con el elemento de estudio. Nace en la década de 1960 con fines militares, sin embargo, a partir de 1970, con el lanzamiento del satélite Landsat del programa EROS, se han utilizado imágenes ópticas de satélite con propósitos civiles, principalmente monitoreo de recursos naturales [8], [25].

La teledetección se basa en registrar los fenómenos de interacción de la radiación en todo el ámbito del espectro electromagnético con la Tierra (Figura 3). Los sensores detectan la radiación que refleja la superficie después de esta interacción. Los sensores poseen una amplia capacidad de detección de frecuencias, incluso aquellas que no son visibles para el ojo humano, como microondas y energía infrarroja [26]. Estas características y los avances tecnológicos, entre los cuales destacan mejoras en la resolución espacial y la agilidad al recopilar información, han ampliado la gama de aplicaciones científicas que se le da a los datos geográficos [27].




Figura 3. Espectro electromagnético [28]

El análisis de información espacial incluye métodos que pueden ser combinados con datos geográficos para valorarlos y revelar patrones o anomalías [29]. Esto representa una ventaja, ya que puede simplificar la comprensión de datos científicos que existen en la actualidad plasmándolos en un mapa. Con este fin, las herramientas existentes se han apoyado en los avances tecnológicos para hacer más accesible la información y facilita a los tomadores de decisiones la incorporación de esos datos en los flujos de trabajo [30].

### 3.6.1 Sensores óptico-electrónicos

Los sensores óptico-electrónicos dispuestos en los satélites entran en la categoría de sensores pasivos, debido a que no emiten su propia radiación. Por lo tanto, dependen del reflejo de la luz solar en la superficie terrestre y de la misma energía que emite la Tierra. Operan en más ventanas atmosféricas que el Radar, es decir zonas del espectro en las cuales la atmósfera produce menos absorción y dispersión de la energía reflejada y emitida: como el rango visible, infrarrojo, infrarrojo térmico y microondas. Están compuestos de instrumentos como radiómetros y espectrómetros que miden la radiación electromagnética y detectan y analizan el contenido espectral de la radiación respectivamente [31].

Existe una amplia variedad de sensores pertenecientes a distintas agencias espaciales, sin embargo, cada uno es diseñado con distintas resoluciones y características para

determinar parámetros específicos. En este caso, interesan aquellos satélites que reúnen las características para proveer información y datos validados sobre fenómenos concernientes a clorofila o turbidez en aguas superficiales. A continuación, se presenta el Cuadro 1, que resume los satélites de la *National Aeronautics and Space Administration* (NASA) en colaboración con la *National Oceanic and Atmospheric Administration* (NOAA), la *U. S. Geological Survey* (USGS) y la *European Space Agency* (ESA), que poseen características para determinar esos parámetros [32].

Como se puede observar en el Cuadro 1, los satélites más adecuados para este proyecto son el Landsat 8 y el Sentinel-2, tanto por sus resoluciones espaciales como temporales. Aunque ambos poseen ciertas ventajas, en las siguientes subsecciones se profundizará en otros rasgos para poder hacer una mejor comparación en el contexto de este proyecto.

Cuadro 1. Resumen de satélites con cualidades para evaluar agua superficial [32]

<b>Satélite</b>	<b>Sensor</b>	<b>Resolución Espacial</b>	<b>Resolución Temporal</b>
Landsat 7	Enhanced Thematic Mapper (ETM)	15, 30, 60 m	16 días
Landsat 8	Operational Land Imager (OLI)	15, 30, 60 m	16 días
Terra and Aqua	Moderate Resolution Imaging Spectroradiometer (MODIS)	250 m, 500 m, 1 km	1-2 días
Suomi NPP	Visible Infrared Imaging Radiometer Suite (VIIRS)	375-750 m	1-2 días
Sentinel-2	Multi Spectral Imager (MSI)	10, 20, 60 m	5 días
Sentinel-3	Ocean and Land Color Instrument (OLCI)	300 m	2 días

### 3.6.1.1 Landsat 8

El programa EROS (*Earth Resources Observation Satellites*) fue el primero que se desarrolló con propósitos civiles, iniciando con el satélite Landsat 1 lanzado en 1972. Su fin consistía en monitorear los cambios en la superficie de la Tierra, mediante recolección de datos sobre la cobertura y uso de suelo o la calidad del agua para vigilar y mejorar la calidad del ambiente. Al ser el programa pionero, cuenta con la ventaja de haber recopilado datos espectrales por más de 40 años, lo que se convierte en la mayor colección de información sobre cambios en la superficie terrestre. Posterior al Landsat 1, se enviaron otros satélites que perfeccionaban en aspectos como resolución espacial (tamaño del pixel), resolución temporal (frecuencia de revisita en la misma área) y resolución radiométrica (sensibilidad de los sensores) gracias a las mejoras en los sensores a bordo del satélite [33], [34].

El último satélite que se lanzó fue el Landsat 8 en el 2013. El observatorio opera en una órbita casi circular, casi polar, sincrónica con el Sol, esto representa una ventaja en estudios ya que permite la adquisición de datos en condiciones comparables. Se encuentra a una altitud de 705 km en el Ecuador y tiene un ciclo de repetición de trayectoria terrestre de 16 días, esta resolución temporal podría resultar una limitación para un estudio que requiera datos diariamente o bien para zonas tropicales en las que hay más nubosidad [35].

Lleva a bordo dos instrumentos, el *Operational Land Imager* (OLI) y el *Thermal Infrared Sensor* (TIRS). El sensor OLI utiliza conjuntos de detectores lineales largos por banda espectral, estos recopilan imágenes en forma de barrido, lo que lo convierte en un instrumento más sensible. OLI tiene un telescopio de cuatro espejos y cuantificación de 12 bits. Este recopila datos para las bandas espectrales visible, infrarroja cercana e infrarroja de onda corta, así como para una banda pancromática. En el Cuadro 2 se especifican los rangos del espectro de cada banda, así como su resolución espacial [35].

Al igual que OLI, TIRS es un sensor de barrido que emplea un plano focal con largas series de detectores fotosensibles. TIRS utiliza fotodetectores infrarrojos de pozo cuántico (QWIP) para medir la energía infrarroja térmica de onda larga (TIR) emitida por la superficie de la Tierra, cuya intensidad es función de la temperatura de la superficie. Los fotodetectores

son sensibles a dos bandas, específicamente la banda 10 y la banda 11, de longitud de onda infrarroja térmica, lo que permite la separación de las temperaturas de la superficie de la Tierra y de la atmósfera [35].

Cuadro 2. Rangos de frecuencia del espectro electromagnético y resolución espacial de los sensores OLI y TIRS del satélite Landsat 8 [35]

<b>Bandas</b>	<b>Longitud de onda (<math>\mu\text{m}</math>)</b>	<b>Resolución (m)</b>
Banda 1 - Aerosol costero	0.43-0.45	30
Banda 2 - Azul	0.45-0.51	30
Banda 3 - Verde	0.53-0.59	30
Banda 4 - Rojo	0.64-0.67	30
Banda 5 - Infrarrojo cercano (NIR)	0.85-0.88	30
Banda 6 - SWIR 1	1.57-1.65	30
Banda 7 - SWIR 2	2.11-2.29	30
Banda 8 - Pancromática	0.50-0.68	15
Banda 9 - Cirrus	1.36-1.38	30
Banda 10 – TIRS 1	10.60-11.19	100
Banda 11- TIRS 2	11.50-12.51	100

### 3.6.1.2 Sentinel 2

La historia de Sentinel-2 es más reciente que la de Landsat. Su origen se remonta a 1998, cuando se firmó el Manifiesto de Baveno, donde se acordaba la creación de un proyecto de monitoreo ambiental y climático llamado entonces *Global Monitoring for Environmental Security* (GMES) y a partir del 2012 nombrado Copernicus. Sin embargo, fue hasta el 2004 que deciden agregar el componente de monitoreo remoto y se firma un acuerdo con la ESA. La familia de satélites inicia con el lanzamiento de Sentinel-1 en el 2014 con un instrumento de radar acoplado [36].

Al año siguiente se lanza Sentinel-2, con la cualidad de que en el 2017 se lanzaría un satélite gemelo, de modo que funcionen simultáneamente (Sentinel-2A y Sentinel-2B). Los mismos están separados 180° en una órbita sincrónica con el sol a una altitud media de 786 km. La preminencia que tienen ambos satélites es la frecuencia de revisita, pues repiten la trayectoria cada 5 días, dando una ventaja sobre la resolución temporal de Landsat 8. Además, como se observa en el Cuadro 3, Sentinel posee una mejor resolución espacial. En cuanto a la resolución radiométrica, Sentinel-2 iguala a Landsat con 12 bits. Por otra parte, la resolución espectral también posee una ventaja frente a Landsat 8, ya que en Sentinel se aplicó una corrección en el ancho de banda del NIR, que evita la contaminación por vapor de agua sin comprometer la sensibilidad por la vegetación y el contenido de óxido de hierro en el suelo. En el Cuadro 3, se especifican esta y las demás bandas con su longitud de onda central y la respectiva resolución espacial, tanto para Sentinel-2A como para Sentinel-2B [37].

Cuadro 3. Longitud de onda central, ancho de bandas y resolución espacial de las bandas del sensor MSI de los satélites Sentinel-2A y Sentinel-2B [38]

Bandas	Sentinel-2A		Sentinel-2B		Resolución (m)
	Longitud de onda central (nm)	Ancho de banda (nm)	Longitud de onda central (nm)	Ancho de banda (nm)	
Banda 1- Aerosol costero	443.9	20	442.3	20	60
Banda 2- Azul	496.6	65	492.1	65	10
Banda 3- Verde	560.0	35	559	35	10
Banda 4- Rojo	664.5	30	665	30	10
Banda 5- Vegetation Red Edge	703.9	15	703.8	15	20
Banda 6- Vegetation Red Edge	740.2	15	739.1	15	20
Banda 7- Vegetation Red Edge	782.5	20	779.7	20	20

Bandas	Sentinel-2A		Sentinel-2B		Resolución (m)
	Longitud de onda central (nm)	Ancho de banda (nm)	Longitud de onda central (nm)	Ancho de banda (nm)	
Banda 8-NIR	835.1	115	833	115	10
Banda 8b-Narrow NIR	864.8	20	864	20	20
Banda 9-Vapor de agua	945.0	20	943.2	20	60
Banda 10-Infrarrojo de onda corta (SWIR) – Cirrus	1373.5	30	1376.9	30	60
Banda 11-SWIR	1613.7	90	1610.4	90	20
Banda 12-SWIR	2202.4	180	2185.7	180	20

El instrumento multiespectral (MSI) funciona con un sensor de barrido, que recopila filas de datos de imágenes a lo largo de la franja orbital y utiliza el movimiento de avance de la nave espacial a lo largo de la trayectoria de la órbita para proporcionar nuevas filas para la adquisición. La luz que recibe el instrumento, reflejada desde la Tierra y su atmósfera, es recolectada por un telescopio de tres espejos (M1, M2 y M3) y enfocada, a través de un divisor de haz, en dos Conjuntos de Plano Focal (FPA): uno para las diez longitudes de onda VNIR y una para las tres longitudes de onda SWIR [37].

### 3.7 Google Earth Engine

Uno de los avances tecnológicos que ha facilitado una mayor apertura de los sistemas de información geográfica es la web. Esta ha permitido manipular los datos geoespaciales de forma distinta. Antes debían ser procesados, modificados y extraídos para responder un parámetro individual, actualmente, los datos son transformados en mapas web que se mezclan con diferentes capas, ofreciendo agilidad y flexibilidad a la hora del trabajo y la búsqueda de respuestas [30].

Los datos geoespaciales, debido a sus características de volumen de información y variedad de datos en tipo y formato, son considerados *Big Data*, pues se trata de mucha información que se recopila continuamente sobre el estado cambiante de la superficie terrestre. Utilizar herramientas comunes de software pueden hacer más lento el proceso de gestionar *Big Data*, se requiere computación de alto rendimiento (HPC) o bien plataformas en nube [39]. GEE es una plataforma de geoprocesamiento para el análisis geoespacial basado en una nube y posee acceso a los servidores de alto rendimiento de Google. Se accede y se controla a través de una interfaz de programación de aplicaciones accesible a través de Internet (API), para Python o JavaScript y posee un entorno de desarrollo interactivo (IDE) asociado que permite la creación rápida de prototipos y la visualización de resultados [4].

GEE cuenta con una base de datos superior a 40 años de recopilación, provenientes de distintos satélites y sistemas de imágenes espaciales, aprovechando la información y datos a escala petabits de sensores remotos que se han obtenido de la NASA, la USGS y la NOAA [5]. Por otro lado, también es posible cargar datos ráster y vectoriales propios. Los ráster se refieren a datos geoespaciales que dividen el mundo en celdas con valores asociados, similares a las imágenes que se dividen en píxeles. Por otra parte, los datos vectoriales son geometrías (pueden ser puntos, líneas, polígonos o una combinación de estos) asociadas a listas de características [40].

El objetivo general de GEE es avanzar en los desafíos más grandes de la sociedad facilitando el monitoreo, rastreo y administración del medio ambiente y los recursos de la Tierra, tal como los Objetivos de Desarrollo Sostenible (ODS). Hacerlo requiere proporcionar acceso no solo a vastas cantidades de datos y potencia computacional, sino también a técnicas de análisis cada vez más sofisticadas [5].

### **3.8 Transformación de imágenes**

Los datos de imágenes satelitales poseen características multiespectrales, como vectores en el espacio, que permiten llevar a cabo transformaciones mediante combinaciones de bandas o bien operaciones matemáticas entre ellas [27]. La primera se basa en el uso de

tres bandas de las capturadas por el sensor y su representación en tonos de verde, rojo y azul, pues de otro modo se dificultaría su interpretación, ya que las bandas originales están en escala de grises (Figura 4). Existen las combinaciones en color verdadero, que representa las bandas verde, rojo y azul en sus tonos correspondientes, dando como resultado una imagen de la tierra como la conocemos. Además, existen las composiciones en falso color, en la cual se combinan bandas con al menos una fuera del rango visible en los tonos primarios, estas combinaciones pueden facilitar la distinción de superficies y revelar coberturas que no serían visibles de otro modo [41].




Figura 4. Representación gráfica de la combinación de bandas representadas en los tonos rojo, verde y azul [42]

Por otro lado, utilizando la aritmética de bandas se pueden reordenar los píxeles de una imagen para resaltar características que no eran evidentes en los datos originales, pero representan una descripción alternativa de estos. Las transformaciones pueden asociarse a aplicaciones particulares, como vegetación, agua o nieve [27].

En el contexto de este proyecto se busca modelar en primer lugar la clorofila-a, un pigmento fotosintético e indicador clave para la determinación de biomasa de fitoplancton relacionado con el aporte de nutrientes a un cuerpo de agua. En segundo lugar, SST como indicador de contaminación y erosión en el Río Sierpe asociado a la agricultura intensiva alrededor del HNTS y el manejo del suelo[22][43]. Para estos parámetros existen distintas operaciones matemáticas entre bandas y sensores (conocidos como índices) que se han probado en correlación con estos parámetros y a partir de los cuales se han generado modelos adecuados para aproximar su concentración o tendencia[43].

En el caso de la clorofila-a, se han utilizado con buenos resultados los datos del sensor MSI de Sentinel-2, el cual suele elegirse especialmente por su resolución temporal y espacial, además posee la banda llamada *Red Edge*, que puede brindar información importante de concentración de fitoplancton, asociado a contenido de clorofila-a en aguas continentales. Esto se debe a la relación de la reflectancia en la banda y parámetros biofísicos de vegetación. Otras bandas de gran utilidad son la del Infrarrojo Cercano (NIR por sus siglas en inglés), el azul y el verde. En cuanto al NIR, ya que la reflectividad en este rango para superficies acuáticas es casi nula, puede variar y manifestar pequeños incrementos si la masa de agua presenta sólidos suspendidos o bien si la profundidad permite la reflectancia del fondo del cuerpo de agua. Por su parte, en los rangos del azul y el verde se dan los mayores picos de reflectancia en los cuerpos de agua [24], [27], [43], [44].

Los modelos para la determinación remota de clorofila y SST se han desarrollado de forma empírica para cada sitio de estudio, toman en cuenta la relación estadística entre la concentración de los parámetros y las señales de reflectancia resultantes de los índices que dependen del tamaño de partícula, densidad y otras complejidades ópticas. No existe un modelo universal para agua continentales [45].

### **3.9 Objetivos de Desarrollo Sostenible**

La teledetección es una herramienta con alcances que se alinean a la agenda 2030 para los ODS, específicamente a los objetivos que se resumen en el Cuadro 4 [46]. La aplicación al monitoreo de humedales como ecosistemas con una amplia gama de beneficios es fundamental para el alcance de estos objetivos. A nivel ambiental los humedales pueden mejorar la calidad del agua, ya que por sus características pueden procesar contaminantes que se han arrastrado hasta ellos. Poseen la capacidad de almacenar grandes volúmenes de agua, que los convierte en una barrera de protección ideal ante inundaciones y fenómenos naturales, que se han hecho más frecuentes por el cambio climático y, además tienen una función importante en el ciclo del carbono. Se estima que retienen entre el 10% y el 20% a nivel mundial. Son el hábitat y la fuente de alimentos de gran variedad de especies, endémicas y migrantes, y también del ser humano. Por estas características, han sido parte del desarrollo

humano desde sus inicios, muchas poblaciones indígenas se asentaron a sus alrededores, por lo que resguardan patrimonios culturales de valor incalculable [47]

Cuadro 4. Resumen de metas asociadas a los ODS de la Agenda 2030 cuyo progreso se puede monitorear con herramientas de teledetección [48]

Objetivos	Aportes a las metas
 <p>6 AGUA LIMPIA Y SANEAMIENTO</p>	<ul style="list-style-type: none"> <li>• Mejorar la calidad del agua</li> <li>• Proteger y restablecer los ecosistemas relacionados con el agua, incluidos los bosques, las montañas, los humedales, los ríos, los acuíferos y los lagos.</li> </ul>
 <p>11 CIUDADES Y COMUNIDADES SOSTENIBLES</p>	<ul style="list-style-type: none"> <li>• Redoblar los esfuerzos para proteger y salvaguardar el patrimonio cultural y natural del mundo.</li> <li>• Reducir significativamente el número de muertes causadas por los desastres, incluidos los relacionados con el agua, y de personas afectadas por ellos, y reducir considerablemente las pérdidas económicas directas provocadas por los desastres.</li> <li>• Aumentar considerablemente el número de ciudades y asentamientos humanos que adoptan e implementan políticas y planes integrados para promover la inclusión, el uso eficiente de los recursos, la mitigación del cambio climático y la adaptación a él y la resiliencia ante los desastres.</li> </ul>
 <p>13 ACCIÓN POR EL CLIMA</p>	<ul style="list-style-type: none"> <li>• Fortalecer la resiliencia y la capacidad de adaptación a los riesgos relacionados con el clima y los desastres naturales en todos los países.</li> </ul>
 <p>14 VIDA SUBMARINA</p>	<ul style="list-style-type: none"> <li>• De aquí a 2025, prevenir y reducir significativamente la contaminación marina de todo tipo, en particular la producida por actividades realizadas en tierra, incluidos los detritos marinos y la polución por nutrientes.</li> </ul>

## 4. Metodología

### 4.1 Lugar de estudio

El río Sierpe se localiza en el Pacífico Sur de Costa Rica en el distrito Sierpe, del cantón de Osa en la provincia de Puntarenas (Figura 5). Su cauce nace en la laguna de Sierpe y se extiende por 82 kilómetros hasta su desembocadura en el océano Pacífico[16].




Figura 5. Ubicación del Río Sierpe en la zona sur de Costa Rica. Elaboración propia

Esta zona se caracteriza por tener un clima tropical húmedo, que aunado a factores geográficos, físicos y bioquímicos favorece el desarrollo de diferentes ecosistemas que se presentan a lo largo del río, tales como el ripario, estuarino, palustrino y lacustrino. Estos ecosistemas a su vez sostienen una amplia biodiversidad, reconocida mundialmente [16].

Las condiciones de la zona facilitan el desarrollo de algunas actividades económicas entre las que destacan la pesca artesanal de moluscos como la piangua, el turismo, la ganadería cárnica y la agricultura de palma aceitera, plátano y arroz. Debe destacarse el reporte de desarrollo de actividades agropecuarias que han modificado el uso de suelo sin respetar la frontera agrícola alrededor de la zona protegida, lo que impacta negativamente el humedal [49].

#### 4.2 Datos de validación

Los datos de validación se obtuvieron por comunicación personal con el investigador Iván Ávila del Laboratorio PRIAS del CeNAT (Centro Nacional de Alta Tecnología), coordinador del proyecto MONEO-WET. En la base de datos construida en campañas realizadas en marzo y noviembre del 2019 y en marzo del 2021, se encuentra la cuantificación de clorofila-a y SST en puntos estratégicos establecidos mediante GPS a lo largo del río hasta su desembocadura, como se muestra en la Figura 6. De este trabajo se obtuvieron 28 datos de validación por parámetro.




Figura 6. Distribución espaciotemporal de las campañas de muestreo en el río Sierpe.  
Elaboración propia

También se trabajó con los datos reportados por Hernández-Alpizar y Mora-Molina [50], en los que se cuantifica la concentración de nitratos y el reporte de crecimiento de plantas acuáticas posterior a la fertilización.

### **4.3 Procesamiento de imágenes satelitales en GEE**

Se utilizó la colección de imágenes atmosféricamente corregidas Copernicus/S2\_SR (nivel 2A) de Sentinel-2. Esta colección se eligió por las ventajas que presenta en resolución espacial, espectral y temporal frente a su contraparte Landsat 8. La resolución temporal fue determinante, ya que al ser una zona tropical que presenta nubosidad constante, se requiere un menor tiempo de revisita para poder aprovechar al máximo escenas con menor saturación de nubes.

El procesamiento de la colección se hace mediante algoritmos de filtrado. El primer filtro correspondió a la eliminación de imágenes con nubosidad mayor al 20% y se enmascararon los píxeles con nubes. Posteriormente, se aplicaron filtros geográficos para obtener únicamente las imágenes en la zona de interés. Finalmente, se definió el periodo de estudio con un filtro temporal desde el 01/01/2019 al 01/01/2020 y del 01/03/2021 al 01/04/2021, que incluye los periodos en que se tienen datos de validación. El filtro anual permite observar un lapso de actividades antropogénicas y cambios climáticos estacionales que pueden influir en la observación de cambios.

En la definición del área de observación se utilizó el archivo shape del río Sierpe del proyecto MONEO-WET, perteneciente al Laboratorio PRIAS. Los puntos de muestreo se recortaron con un margen (*buffer*) de 5 m, de estos se obtuvieron los estadísticos necesarios para el análisis.

Para la modelación de los parámetros se declararon las variables de programación con las siguientes ecuaciones. En el caso de la clorofila-a se recopilaron dos modelos probados en Colombia y Estonia para determinar la concentración de este parámetro en aguas continentales. El primero es una ecuación lineal cuya variable independiente es el índice

Sentinel-2 (1), compuesto por la relación de las bandas Red Edge 1 que abarca los datos entre 695,5 nm y 710,5 nm y se corresponden con la máxima reflectancia que exhibe la vegetación, y la banda azul entre 464,1 nm y 529,1 nm donde se encuentra la máxima reflectancia del agua [44], [51].  $R_{706}$  y  $R_{490}$  representan los valores centrales.

$$55,83 \cdot \frac{R_{706}}{R_{490}} + 35,08 \quad (1)$$

Un segundo modelo utilizado en Estonia (Ecuación 2), al igual que el anterior, es una ecuación lineal, aunque en este caso la variable independiente es un índice compuesto por la diferencia entre la banda Red Edge 1 y la mitad del cociente obtenido de la sumatoria de la banda Roja, (649,5 -679,5 nm) y la banda Red Edge 2 (732,7 -747,7 nm) [44].

$$2231 \cdot \left( RE1 - \left( \frac{R + RE2}{2} \right) \right) + 12,7 \quad (2)$$

En cuanto al material particulado se probaron ecuaciones generadas en la modelación de la concentración de SST en un embalse en Colombia con el satélite Landsat 8 [45]. De las ecuaciones investigadas en este trabajo se seleccionaron la que tuvo mejores resultados, una función polinómica de orden tres con relación del verde (542,5-577,5 nm) y el infrarrojo cercano (NIR) (775,5-890,5 nm) (Ecuación 3) y otra que también mostró buenos resultados (Ecuación 4), la cual relaciona el NIR con la banda Red (650-680 nm).

$$SST = -229,34 \cdot \left( \frac{Green}{NIR} \right)^3 + 1001,65 \cdot \left( \frac{Green}{NIR} \right)^2 - 1422,7 \cdot \left( \frac{Green}{NIR} \right) + 665,17 \quad (3)$$

$$SST = -161,98 \cdot \left( \frac{NIR}{Red} \right)^3 + 713,47 \cdot \left( \frac{NIR}{Red} \right)^2 - 811,43 \cdot \left( \frac{NIR}{Red} \right) + 278,46 \quad (4)$$

El resultado del modelaje se añadió como una nueva banda que almacena los datos de concentración estimada para los parámetros de interés. Para la visualización de la clorofila en el modelo (1) se declararon los parámetros en una variable, con valor mínimo de reflectancia 0 y máximo de reflectancia 300. En el segundo modelo de clorofila (2) se

estableció un mínimo de 0 y un máximo de 70, además se dividió el ámbito de resultados en 10 clases con un color representativo por clase. En el caso de sólidos suspendidos en el primer modelo (3) de este parámetro se estableció un mínimo de -500 y máximo de 500 y el segundo modelo (5) un mínimo de 0 y un máximo de 150, igualmente con 10 clases y un color representativo para cada una.

Como se indicó anteriormente, para obtener los estadísticos de los píxeles en los puntos de interés, se estableció un radio de 5 m alrededor de cada punto modelado, y para esta área se generaron series de tiempo con el valor promedio del área alrededor del punto en cada imagen de la colección.

Se calculó el porcentaje del error absoluto medio (MAPE) en la cuantificación de los parámetros con respecto al grupo de datos de validación. Este procedimiento se resume en la Figura 7 y el código de programación se adjunta en la sección de Anexos.

Los resultados del MAPE fueron utilizados para realizar ajustes del modelaje de los parámetros.




Figura 7. Diagrama de flujo del proceso para la determinación de los parámetros clorofila-a y SST por medio de imágenes satelitales procesadas en GEE. Adaptado de Ruíz Ramírez [45]

## 5. Resultados y discusión

### 5.1 Clorofila-a

#### 5.1.1 Validación de clorofila-a

La Ecuación 2 de clorofila-a se descartó por el alto porcentaje de error (superior a 1000%). La Ecuación 1, que inicialmente mostraba altos porcentajes de error fue ajustada explorando factores divisores entre 1 y 100, ya que los resultados mostraban una proporcionalidad con los datos de validación. Es decir, la tendencia era la misma, pero el resultado cuantitativo se diferenciaba por un factor sistemático. El modelo ajustado para clorofila se muestra en la Ecuación 5.

$$1,1116 \cdot IS2 + 0.7016 \quad (5)$$

Para evaluar el comportamiento del modelo, se generó un gráfico de dispersión que compara las concentraciones de laboratorio con las concentraciones estimadas por el modelo (Figura 8). Al comparar la distribución de los puntos en la gráfica, el modelo sigue una tendencia que se encuentra dentro del ámbito de los datos de laboratorio, aunque el rango en los datos modelados es menor, con propensión a subestimar concentraciones. También se puede apreciar en la gráfica de tendencia lineal, que, aunque es similar, con una pendiente positiva, aún se pueden realizar ajustes en la pendiente para disminuir el error. La mayor diferencia se observa en la última campaña, en la que todas las concentraciones modeladas estuvieron subestimadas, lo que puede afectar la visualización. Por otra parte, debe prestarse especial atención a la pendiente positiva, asociada con el aumento de 28,22% que se dio en el promedio de concentración de clorofila de marzo del 2019 a marzo del 2021 en los datos de MONEO, pues si las prácticas inadecuadas en la fertilización de los cultivos continúan puede darse un aumento gradual en la concentración de clorofila y provocar el deterioro ambiental del Río Sierpe.

La exactitud del modelo se puede cuantificar mediante el error porcentual absoluto medio o MAPE, por sus siglas en inglés, que dio un resultado de 55,29%, un valor que se ve afectado por las diferencias entre los valores, pero que también se puede ver afectado cuando los valores reales son cercanos a 0, como es el caso de las concentraciones de clorofila [57].




Figura 8. Gráfico de dispersión para comparar el comportamiento de los datos de concentración generados por el modelo (5) con los datos de laboratorio

### 5.1.2 Modelos de clorofila-a

Del modelaje se obtuvieron 43 imágenes generadas a partir de la banda resultado de la Ecuación 5. En los píxeles de esta nueva banda se almacenan los resultados modelados de concentración. La banda se procesó con las herramientas de visualización de GEE, con las que se estableció un valor mínimo de 1 y un máximo de 3,5. Con las imágenes procesadas se construyó una animación llamada *filmstrip* para facilitar la visualización de la evolución de la concentración de la clorofila durante el año 2019.

En la Figura 9 se observa el modelaje de clorofila para marzo del 2019, resultado de la ecuación ajustada del modelo (5) que da la concentración de este parámetro a lo largo del Río Sierpe. Se analiza el mes completo y en la figura se observan tres imágenes seleccionadas para la validación al ser coincidentes o más cercanas al día de muestreo.

Se aprecia que las mayores concentraciones se encuentran en la laguna y las zonas más angostas del río (píxeles verdes, amarillos y rojos). Por el contrario, las menores concentraciones se encuentran en las desembocaduras (píxeles azules), lo que coincide con los resultados de laboratorio. Se distingue una evolución descendente en las concentraciones dentro del mismo mes (Figuras 9.a, 9.b), que concuerda con la entrada gradual (no constante) de las lluvias, ya que se aprecia un nuevo aumento en la concentración en la Figura 9.c, asociado también a la dinámica del río que arrastra material hasta la desembocadura.




Figura 9. Modelación de clorofila para los días coincidentes con las fechas de muestreo: a. 07/03/2019, b. 12/03/2019, c. 27/03/2019.

El modelaje de la clorofila-a para las fechas de noviembre y diciembre presenta variaciones marcadas en las diferentes fechas. Seleccionando dos imágenes con cinco días de diferencia, se observa que el 22 de noviembre (Figura 10.a) presenta una concentración mayor que el 27 de noviembre (Figura 10.b). Incluso en la laguna, que normalmente se mantiene con una mayor concentración por su cualidad de ser un cuerpo de agua más estático, se aprecia una concentración mucho menor. En la imagen obtenida para el 2 de diciembre (Figura 10.c) vuelve a aumentar la concentración, esta vez de forma más uniforme, pues incluso se nota el incremento en las desembocaduras. Los cambios que se perciben se pueden atribuir a una onda tropical que afectó al país durante los días 27, 28 y 29 de noviembre, fecha que coincide con la Figura 9.b, donde se aprecia la menor concentración y que se puede deber al aumento en las precipitaciones pues hay mayor dilución. La onda tropical interrumpió la entrada de la época seca, lo que explica el aumento de concentración en los días previos y posteriores al paso de este fenómeno atmosférico [53].




Figura 10. Modelación de clorofila para los días coincidentes con las fechas de muestreo: a. 22/11/2019, b. 27/11/2019, c. 02/12/2019.

El modelo de marzo del 2021 se presenta en la Figura 11. Como se puede observar este no varía sustancialmente de la última imagen de diciembre en la que se presenta una distribución uniforme de la concentración en toda el área del río, en el ámbito intermedio-bajo que se presenta en color cián (Figura 10.c), pues aparenta una ligera disminución en puntos como la laguna y las desembocaduras, sin embargo, la concentración en el área restante permanece constante, igualmente sucede al comparar la imagen de finales de marzo 2019 (Figura 9.c) con la Figura 11. Por lo que es factible deducir que durante la época seca las concentraciones se mantienen, en su mayoría con una concentración similar.




Figura 11. Modelación de clorofila coincidente con fechas de muestreo de marzo 2021

La clorofila-a puede utilizarse como un indicador del estado trófico de un cuerpo de agua, y de acuerdo con los valores de referencia para los niveles tróficos, los resultados obtenidos del modelaje, que coinciden con los datos de validación, se encuentran en estado oligotrófico, es decir poco nutrido [54], [55]. La poca disponibilidad de nutrientes para el crecimiento de plantas que se encuentran en el caudal del río puede deberse a que en este momento aún no se ha fertilizado (marzo) o está muy diluido en época lluviosa. Sin embargo,

otros estudios han confirmado que existen aumentos temporales en la concentración de nitratos asociados directamente a las actividades de fertilización (que se da dos veces al año), en períodos de transición entre la época seca y la época lluviosa, específicamente entre abril y junio y una segunda vez en octubre [50]. Adicionalmente un estudio que modeló la concentración de ion nitrato en ríos de Costa Rica, posicionó el Río Sierpe con concentraciones moderadas y muy altas, asociadas a la práctica de fertilización de los cultivos de palma [56].

La colección de imágenes de Sentinel utilizada es nivel 2A, pertenece a las imágenes llamadas BOA que indican que la reflectancia ha sido corregida para tener escenas sin ruido de la atmósfera [37]. Sin embargo, esta corrección no es apta para la dinámica y complejidad óptica de los ríos por lo que puede aumentar la incertidumbre al modelar datos. Estas variables requieren mayor precisión a la hora de corregir las imágenes. Por esto, es recomendable utilizar una rutina de corrección más precisa para aguas continentales [44], [58]. Otra razón que pudo afectar la recuperación de datos mediante el modelo es el mismo parámetro de clorofila, específicamente si proviene de cianobacterias, pues estos organismos tienden a formar floraciones en la superficie que pueden ser arrastradas por el viento y en el caso del Pacífico Sur se registran vientos en diferentes direcciones durante el día, donde predominan vientos ecuatoriales y brisa marina en horas del día desde el oeste, mientras que en las noches los vientos provienen del norte desde la Cordillera de Talamanca [59], esto quiere decir que los microorganismos que poseen este pigmento podrían cambiar su posición en distintas horas del día, por lo que es ideal disminuir el margen de tiempo entre la toma de muestra y el paso del satélite para obtener datos más fiables.

## **5.2 SST**

### **5.2.1 Validación de SST**

En el caso de SST se descartó el modelo (3) por la gran diferencia entre las concentraciones reales y las modeladas. El modelo (4) se descartó por el error significativo que presentó, sin embargo, exhibió un comportamiento que podría ajustarse para futuros estudios, por lo que se discute a continuación.

En el gráfico de dispersión (Figura 12) se pueden visualizar de forma puntual los cambios entre los valores obtenidos en el laboratorio y los modelados en GEE. El modelo tendió a subestimar los valores de concentración, incluso hay un resultado negativo en la tercera campaña, sin embargo, al observar la distribución se aprecia mucha similitud entre los valores reales y los modelados, lo que quiere decir que el índice de la banda NIR entre la banda roja puede dar buenos resultados. Por otra parte, el MAPE dio 185% para este modelo, este resultado hace descartar el modelo por el error significativo, sin embargo, no se debe excluir la posibilidad de que mediante métodos numéricos se pueda generar una nueva ecuación que se adapte adecuadamente al Río Sierpe.




Figura 12. Gráfico de dispersión para comparar el comportamiento de los datos de concentración generados por el modelo (5) con los datos de laboratorio

### 5.2.2 Modelos de SST

Los resultados del modelaje para marzo del 2019 (Figura 13) muestran concentraciones bajas de SST en la mayor parte del río, aunque destacan en rojo ciertas zonas con concentraciones más altas, en particular el centro de la laguna, en la que se observa un aumento gradual de la imagen 13.a a la 13.c y la zona en la que el caudal del río se divide en tres bocas, principalmente en secciones curvas del río y donde es más angosto. Finalmente, en las desembocaduras se observan las menores concentraciones, esto se puede deber al cambio de velocidad en el flujo que permite la deposición de sedimentos [13].




Figura 13. Modelación de SST para los días coincidentes con las fechas de muestreo: a. 07/03/2019, b. al 12/03/2019, c. 27/03/2019

En la Figura 14, se muestra el modelaje de SST para noviembre y diciembre del 2019. Se puede apreciar el aumento de la concentración en más zonas del río, principalmente en las desembocaduras, encontrando la mayor concentración en la Figura 14.a. Al comparar con los resultados de laboratorio, se podría decir que existe una sobreestimación de las concentraciones en el modelo, ya que los datos de laboratorio en las campañas de marzo y noviembre del 2019 se mantuvieron muy cercanos y en el modelo de noviembre se aprecian diferencias superiores.




Figura 14. Modelación de SST para los días coincidentes con las fechas de muestreo: a. 22/11/2019, b. 27/11/2019, c. 02/12/2019.

En la Figura 15 se muestra el modelo para marzo del 2021. En esta se visualiza un nuevo decrecimiento en la concentración de SST, en este caso parece existir una subestimación de la concentración, pues el promedio de la concentración en laboratorio en marzo del 2021 fue casi 8 veces mayor que la de las primeras dos campañas de muestreo, por lo que se podía inferir que predominarían los colores amarillos, anaranjados y rojos en esta imagen, sin embargo, predominan las áreas en azul, indicando una concentración más bien menor.




Figura 15. Modelación de SST coincidente con fechas de muestreo de marzo 2021

En el caso de los modelos de SST, se puede observar que no se presentó una diferencia estacional tan marcada en los resultados de laboratorio, principalmente por el aumento de casi ocho veces en el promedio para marzo del 2021. Se debe prestar especial atención a ese aumento significativo, pues los SST reflejan los mayores problemas de contaminación por arrastre de material particulado que se da en los drenajes de los cultivos [60]. En cuanto al modelo, este presentó un dato negativo, que como se discutió antes sobre los resultados de los modelos de clorofila, tiene que ver con la corrección que se utiliza para las imágenes nivel 2A de Sentinel, que afecta la recuperación de los datos, pues no es apta para cuerpos de agua como los ríos por su dinámica [58]. En particular la recuperación de SST puede ser más

complicada, pues su aumento o disminución depende de la turbulencia de las aguas del río, que se ve afectada por la velocidad, regímenes de inundación, el tiempo de retención del agua y las áreas de vegetación colindantes [13]. Normalmente, la concentración puede aumentar en época lluviosa debido a que las precipitaciones afectan el caudal del río [61]. Al evaluar las precipitaciones de esos años en los boletines mensuales del Instituto Meteorológico Nacional (IMN), en marzo 2019 predominó la época seca, aunque inició la transición hacia la época lluviosa, por lo que se presentaron precipitaciones con montos entre 30 y 160 mm, lo que explica las bajas concentraciones que se perciben en el modelo. Por otra parte, en noviembre se observa un déficit de lluvia en el Pacífico Sur de un 40% debido a la transición hacia la época seca, sin embargo, el país se vio afectado por empujes fríos y una onda tropical a finales del mismo mes. Esto explica por qué se percibe una concentración mayor en los modelos de noviembre. Finalmente, en marzo del 2021 se presentaron anomalías negativas de lluvias en el Pacífico Sur, predominando los días secos, lo que pudo provocar una mayor concentración de SST que se vio reflejada en los resultados de laboratorio y en algunas zonas del río en el modelo [53], [62], [63].

### **5.3 Observación de modificaciones**

Con el fin de probar la aplicabilidad de la teledetección en zonas tropicales en la observación de modificaciones de ríos, se analizaron imágenes correspondientes al periodo indicado por el estudio del impacto de la fertilización en el contenido de nitratos y el crecimiento de plantas acuáticas de Hernández-Alpizar y Mora-Molina. En este trabajo los autores observaron un pico de nitratos en mayo que relacionaron con el crecimiento de vegetación acuática en los meses siguientes [50]. La imagen que sobresale de las 43 generadas a partir del modelo es la del 5 de julio del 2019 (Figura 16), ya que exhibió la concentración mayor de clorofila de todas las imágenes. Como se observa en la Figura 18, las partes más angostas del río presentaron concentraciones intermedias a altas de clorofila-a. Esto está en total congruencia con lo obtenido en el trabajo de investigación mencionado.




Figura 16. Modelaje de clorofila para el mes de julio del 2019

## **6. Conclusiones y recomendaciones**

### **6.1 Conclusiones**

Se modelaron modificaciones de clorofila-a y material particulado (SST) en el río Sierpe con bases de datos atmosféricamente corregidas de Sentinel-2 y modelos utilizados anteriormente en estudios de aguas continentales en Colombia. Estos se validaron con los resultados obtenidos de tres campañas de muestreo hechas por el laboratorio PRIAS para el proyecto MONEO-WET, en marzo del 2019, noviembre del 2019 y marzo del 2021.

Se determinó que el uso de datos satelitales es aplicable para la observación de modificaciones de clorofila-a y SST en las diferentes épocas del año a nivel territorial. Las imágenes obtenidas muestran distribuciones congruentes con respecto a las dinámicas de estos parámetros en relación con el clima y las actividades antropogénicas. Sin embargo, se deben realizar ajustes para disminuir el error en la estimación cuantitativa.

Estos resultados sientan un precedente en el uso de imágenes satelitales y modelaje para la gestión ambiental integral de territorios tropicales, vulnerables por las prácticas inadecuadas en la agricultura y otras actividades humanas.

Esta herramienta permite dar un seguimiento de todo el territorio de interés con un mínimo de cinco días de diferencia, lo cual representa una ventaja espacio-temporal frente a los muestreos tomados en solo un punto y que se hacen con meses de diferencia .

La teledetección es una gran aliada para el alcance de los ODS, pues potencia la vigilancia y protección del recurso hídrico y los ecosistemas acuáticos, aporta al desarrollo sostenible de las actividades antropogénicas y aprovecha la cooperación internacional en el manejo de datos e información

## 6.2 Recomendaciones

Se recomienda continuar con el ajuste de funciones de modelación para mejorar la precisión en estimación cuantitativa.

Los errores se pueden disminuir con cambios en la rutina de corrección, ya que la corrección Sen2cor utilizada para la colección de imágenes nivel 2A de Sentinel-2 afectó la recuperación de los datos modelados de concentración de clorofila-a y SST, pues su diseño está hecho para ecosistemas terrestres, lacustres y costeros más estáticos. Otros factores como el dinamismo del río, el viento y el lapso entre la toma de muestra y el paso del satélite inciden negativamente en la recuperación de datos modelados. Por otra parte, con la modificación del modelo (1) de clorofila se pudo comprobar que el error puede disminuir significativamente.

Se recomienda ampliar la cantidad de parámetros para el modelaje.

Es importante la toma de muestras más constante y cercana al paso del satélite para construir una base de datos que suministre información para la validación de nuevos modelos matemáticos.

Es necesario ofrecer y difundir el uso de modelos con teledetección para una gestión integral y amplia de los territorios, que es un fin fundamental de la ingeniería ambiental.

## 7. Referencias

- [1] National Geographic Society, “Watershed,” 2019. <https://www.nationalgeographic.org/encyclopedia/watershed/>
- [2] M. J. R. Dixon, J. Loh, N. C. Davidson, C. Beltrame, R. Freeman, and M. Walpole, “Tracking global change in ecosystem area: The Wetland Extent Trends index,” *Biol Conserv*, vol. 193, pp. 27–35, 2016, doi: 10.1016/j.biocon.2015.10.023.
- [3] H. M. Pereira *et al.*, “Essential Biodiversity Variables,” *Science (American Association for the Advancement of Science)*, vol. 339, no. 6117, pp. 277–278, 2013, doi: 10.1126/science.1229931.
- [4] Google Developers, “Earth Engine Code Editor,” 2021. <https://developers.google.com/earth-engine/guides/playground>
- [5] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore, “Google Earth Engine: Planetary-scale geospatial analysis for everyone,” *Remote Sens Environ*, vol. 202, pp. 18–27, 2017, doi: 10.1016/j.rse.2017.06.031.
- [6] R. B. Eckert, “Organic Phase Analysis,” in *Field Guide to Internal Corrosion Mitigation and Monitoring for Pipelines*, 2016.
- [7] R. Kohli and K. L. Mittal, “Eutrophication,” in *Developments in Surface Contamination and Cleaning: Cleaning Techniques*, Elsevier, Ed. Elsevier, 2015, p. 22.
- [8] U S Geological Survey, “Landsat—Earth observation satellites (ver. 1.2, April 2020): U.S. Geological Survey Fact Sheet 2015–3081.” 2016. [Online]. Available: <https://pubs.er.usgs.gov/publication/fs20153081>
- [9] V. Chacón, “Esta larga pesadilla de los agroquímicos en Costa Rica,” *Semanario Universidad*, 2018. [Online]. Available: <https://semanariouniversidad.com/pais/esta-larga-pesadilla-de-los-agroquimicos-en-costa-rica/#:~:text=Su%20uso%20en%20el%20pa%C3%ADs,%2C1%25%20en%20el%202014>
- [10] C. Leiva and J. R. Vargas, “La productividad, el uso de tecnologías en los productos agrícolas y tendencias futuras,” *UNA VISIÓN DEL SECTOR AGROPECUARIO BASADA EN EL CENAGRO*. INEC, 2017.
- [11] PEN-CONARE, “Estado de la Nación 2020,” 2020. [Online]. Available: <https://repositorio.conare.ac.cr/handle/20.500.12337/7992>
- [12] FAO, “FAOSTAT. Fertilizers by Product,” 2022. <https://www.fao.org/faostat/en/#data/RFB>
- [13] S. K. Ong, R. Y. Surampalli, A. Bhandari, P. Champagne, R. D. Tyagi, and I. Lo, “Abiotic Factors Influencing Wetland Processes,” in *Natural Processes and Systems for Hazardous Waste Treatment*, A. S. of C. Engineers, Ed. 2008, pp. 209–218.
- [14] EPA, “What are the trends in the extent and condition of wetlands and their effects on human health and the environment?,” 2022. <https://www.epa.gov/report-environment/wetlands>
- [15] R. C. on Wetlands, “Global Wetland Outlook: State of the world’s wetlands and their services to people 2018.” Gland, Switzerland: Ramsar Convention Secretariat, 2018. [Online]. Available: [https://medwet.org/wp-content/uploads/2018/09/ramsar\\_gwo\\_english\\_web.pdf](https://medwet.org/wp-content/uploads/2018/09/ramsar_gwo_english_web.pdf)

- [16] S. Lobo Cabezas, G. M. Alvarado Quesada, F. J. Durán Alvarado, A. Ruiz Boyer, and A. Quesada Hernández, “DIVERSIDAD BIOLÓGICA DEL DIQUÍS II: Humedal Térraba-Sierpe.” Museo Nacional de Costa Rica, San José, Costa Rica, 2014.
- [17] SINAC-PNUD-GEF, “Inventario Nacional de Humedales,” San José, 2018.
- [18] P. Blanco-Picado, “Plaguicida usado en piña presente en Humedal Térraba-Sierpe,” *Crisol. Suplemento de Ciencia y Tecnología*, no. 284, pp. 2–3, 2014, [Online]. Available: <https://odi.ucr.ac.cr/medios/documentos/suplemento-crisol/Crisol284.pdf>
- [19] MINAE, “Política Nacional de Humedales .” 2017.
- [20] L. Hernández Alpízar, J. Mora Molina, and R. Coy Herrera, “Monitoreo de nitratos en los drenajes de palma aceitera (*Elaeis guineensis*)- una herramienta para la sostenibilidad del cultivo,” *UNED Research Journal (e-ISSN 1659-441X)*, vol. 12, no. 1, 2020, [Online]. Available: <https://www.scielo.sa.cr/pdf/cinn/v12n1/1659-4266-cinn-12-01-027.pdf>
- [21] I. Goswami, “Water Supply Quantity and Quality ,” in *Civil Engineering All-In-One PE Exam Guide: Breadth and Depth, Second Edition*, McGraw-Hill, 2012.
- [22] E. W. Rice, R. B. Baird, and A. D. Eaton, *Standard Methods for the Examination of Water and Wastewater* , 23rd ed. 2017.
- [23] R. M. Harrison, “Eutrophication,” in *Pollution - Causes, Effects and Control (5th Edition)*, Royal Society of Chemistry, 2014, p. 87.
- [24] S. Mahdavi, B. Salehi, J. Granger, M. Amani, B. Brisco, and W. Huang, “Remote sensing for wetland classification: a comprehensive review,” *GIsci Remote Sens*, vol. 55, no. 5, pp. 623–658, 2018, doi: 10.1080/15481603.2017.1419602.
- [25] C. Pérez-Gutiérrez and A. Muñoz-Nieto, *Teledetección: Nociones y aplicaciones*. Universidad de Salamanca, 2006.
- [26] European Space Agency, “Teledetección, a fondo,” 2020. [https://www.esa.int/SPECIALS/Eduspace\\_ES/SEMZ3YD3GXF\\_0.html](https://www.esa.int/SPECIALS/Eduspace_ES/SEMZ3YD3GXF_0.html)
- [27] J. A. Richards, “Remote Sensing Digital Image Analysis: An Introduction,” Springer, Berlin, Heidelberg, 2012. doi: 10.1007/978-3-642-30062-2.
- [28] NASA, “Introduction to the Electromagnetic Spectrum,” 2021. [https://science.nasa.gov/ems/01\\_intro](https://science.nasa.gov/ems/01_intro)
- [29] P. A. Longley, M. F. Goodchild, D. J. Maguire, and D. W. Rhind, “Introduction: What is spatial analysis?,” in *Geographic Information Science & Systems*, J. W. & Sons, Ed. 2015, pp. 290–291.
- [30] S. R. Shrestha, M. Tisdale, S. Kopp, and B. Rose, “Earth Observation and Geospatial Implementation: Fueling Innovation in a Changing World,” *Earth Observation, Open Science and Innovation*, vol. 15, pp. 301–310, 2018.
- [31] NASA, “What is remote sensing?,” 2022. <https://www.earthdata.nasa.gov/learn/backgrounders/remote-sensing>
- [32] NASA, “Water Quality Data Pathfinder ,” 2019. <https://www.earthdata.nasa.gov/learn/pathfinders/water-quality-data-pathfinder>
- [33] U S Geological Survey, “Landsat Satellite Missions,” 2021. [https://www.usgs.gov/landsat-missions/landsat-satellite-missions?qt-science\\_support\\_page\\_related\\_con=0#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/landsat-missions/landsat-satellite-missions?qt-science_support_page_related_con=0#qt-science_support_page_related_con)
- [34] P. Gupta and M. Follete-Cook, “Fundamentals of Satellite Remote Sensing,” *Applied Remote Sensing Training Program* . Applied Remote Sensing Training Program NASA, pp. 22–30, 2018.

- [35] USGS, “Landsat 8 (L8) Data Users Handbook.” 2019. [Online]. Available: [https://prd-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/atoms/files/LSDS-1574\\_L8\\_Data\\_Users\\_Handbook-v5.0.pdf](https://prd-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/atoms/files/LSDS-1574_L8_Data_Users_Handbook-v5.0.pdf)
- [36] European Commission, “Copernicus, 20 years of History.” 2018. [Online]. Available: [https://www.copernicus.eu/sites/default/files/2018-10/History\\_Factsheet\\_vf.pdf](https://www.copernicus.eu/sites/default/files/2018-10/History_Factsheet_vf.pdf)
- [37] European Space Agency, *Sentinel-2 User Handbook*. 2015.
- [38] Earth Observing System, “Sentinel-2.” <https://eos.com/find-satellite/sentinel-2/>
- [39] H. Tamiminia, B. Salehi, M. Mahdianpari, L. Quackenbush, S. Adeli, and B. Brisco, “Google Earth Engine for geo-big data applications: A meta-analysis and systematic review,” *ISPRS journal of photogrammetry and remote sensing*, vol. 164, pp. 152–170, Jun. 2020, doi: 10.1016/j.isprsjprs.2020.04.001.
- [40] E. Westra, “Understanding Geospatial Data,” in *Python Geospatial Analysis Essentials*, Packt Publishing, 2015, pp. 2–5.
- [41] Earth Observatory, “Turning Wavelength Data Into an Image,” 2014. <https://earthobservatory.nasa.gov/features/FalseColor/page3.php>
- [42] A. Kekesi, “Florida Everglades LDCM Band Remix,” 2013. <https://svs.gsfc.nasa.gov/vis/a000000/a004000/a004040/>
- [43] I. Martínez García, “Monitorización de la calidad del agua en embalses mediante técnicas de observación remota,” Universidad de Cantabria, 2017.
- [44] K. Toming, T. Kutser, A. Laas, M. Sepp, B. Paavel, and T. Noges, “First Experiences in Mapping Lake Water Quality Parameters with Sentinel-2 MSI Imagery,” *Remote sensing (Basel, Switzerland)*, vol. 8, no. 8, p. 640, 2016, doi: 10.3390/rs8080640.
- [45] D. C. Ramírez-Ruiz, “Método de Estimación de Sólidos Suspendidos Totales como Indicador de la Calidad del Agua Mediante Imágenes Satelitales,” 2017.
- [46] NASA, “Geospatial information and Earth observations supporting official statistics in monitoring the U.N. Sustainable Development Goals,” 2016.
- [47] R. C. Smardon, *Sustaining the world’s wetlands*. New York: Springer, 2009. [Online]. Available: <https://agris.fao.org/agris-search/search.do?recordID=#61>
- [48] N. Unidas, “Objetivos de Desarrollo Sostenible,” 2022. <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- [49] G. Cortés-Munoz and N. Montero-Solís, “La frontera agrícola en las áreas aledañas al Humedal Nacional Terraba Sierpe y sus implicaciones en la sostenibilidad de los sistemas productivos,” *e-agronegocios*, vol. 7, pp. 56–77, 2021, doi: 10.18845/ea.v7i1.5317.
- [50] L. Hernández Alpízar and J. Mora Molina, “Nitrates Evaluation in the National Terraba-Sierpe Wetland,” *Uniciencia*, vol. 36, no. 1, pp. 1–11, 2022, doi: 10.15359/ru.36-1.10.
- [51] J. Delegido, C. Tenjo, A. Ruíz-Verdú, R. Pena, J. Moreno, and A. E. de Teledetección., “Modelo empírico para la determinación de clorofila-a en aguas continentales a partir de los futuros Sentinel-2 y 3. Validación con imágenes HICO,” *Revista de Teledetección*, vol. 41, pp. 37–47, 2014.
- [52] Google Developers, “ImageCollection Visualization,” 2021. [https://developers.google.com/earth-engine/guides/ic\\_visualization?hl=en](https://developers.google.com/earth-engine/guides/ic_visualization?hl=en)
- [53] Instituto Meteorológico Nacional, “Boletín Meteorológico Noviembre 2019,” 2019.

- [54] Ministerio de Ambiente Uruguay, “Concentración de Clorofila-a en agua superficial,” 2021. [https://www.ambiente.gub.uy/indicadores\\_ambientales/ficha/oan-concentracion-de-clorofila-a/](https://www.ambiente.gub.uy/indicadores_ambientales/ficha/oan-concentracion-de-clorofila-a/)
- [55] M. Matthews and S. Bernard, “Eutrophication and cyanobacteria in South Africa’s standing water bodies: a view from space,” *S Afr J Sci*, vol. 111, no. 5/6, p. 1, 2015, doi: 10.17159/sajs.2015/20140193.
- [56] J. Rojas Zamora, “Modelaje de la concentración del ion nitrato en las aguas superficiales de Costa Rica,” 2022.
- [57] Minitab, “Interpretar todos los estadísticos y gráficas para Promedio móvil,” 2022. <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/time-series/how-to/moving-average/interpret-the-results/all-statistics-and-graphs/>
- [58] C. Kuhn *et al.*, “Performance of Landsat-8 and Sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity,” *Remote Sens Environ*, vol. 224, no. 224, pp. 104–118, Apr. 2019, doi: 10.1016/j.rse.2019.01.023.
- [59] Instituto Meteorológico Nacional, “Pacífico Sur Clima.”
- [60] A. G. Pérez-Castillo, R. Barboza-Mora, and F. Ramos-Matarrita, “CALIDAD DEL AGUA DEL REFUGIO MATA REDONDA Y LOS ARROZALES COLINDANTES, GUANACASTE, COSTA RICA ,” *AGRONOMÍA MESOAMERICANA*, vol. 24, no. 2, 2013.
- [61] M. del M. Solano Arce, “Impacto ambiental por aguas residuales y residuossólidos en la calidad del agua de la parte media-alta de la microcuenca del río Damasy propuesta de manejo,” Universidad Nacional de Costa Rica, 2011.
- [62] Instituto Meteorológico Nacional, “Boletín Meteorológico Marzo 2019,” 2019.
- [63] Instituto Meteorológico Nacional, “Boletín Meteorológico Marzo 2021,” 2021.

## 8. Anexos

### 8.1 Anexo 1: Código utilizado para el modelaje de Clorofila-a

```
//////////////////////////////////// Colección de imágenes////////////////////////////////////

// Cargamos la función que enmascara píxeles nubosos

/**
 * Function to mask clouds using the Sentinel-2 QA band
 * @param {ee.Image} image Sentinel-2 image
 * @return {ee.Image} cloud masked Sentinel-2 image
 */
function maskS2clouds(image) {
  var qa = image.select('QA60');

  // Bits 10 and 11 are clouds and cirrus, respectively.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;

  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));

  return
  image.updateMask(mask).divide(10000).copyProperties(image, ['system:time_s
  tart']);
}
//Se declara la variable de la coleccion de imagenes y se filtra por
fecha y region de interes
var s2_ic_filt = ee.ImageCollection('COPERNICUS/S2_SR')
  .filterDate('2021-03-20', '2021-03-30')
  .filterBounds(puntos_sierpe)
  // Pre-filter to get less cloudy granules.
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20))
  .map(maskS2clouds);

var visualization = {
  min: 0.0,
  max: 0.3,
  bands: ['B4', 'B3', 'B2'],
};

print(s2_ic_filt, 'Colección de imágenes Sentinel-2 filtrado por fecha y
región');

//
Map.setCenter(-83.4746, 8.8679, 12);
```

```

//Se agrega la capa con un promedio .mean() de las imágenes

Map.addLayer(s2_ic_filt.mean(), visualization, 'RGB');

var bandas = s2_ic_filt.first().bandNames();
print (bandas, "Bandas Sentinel 2");

//////////CLIP TO COLLECTION IMAGES

// Funcion para recortar con los limites del rio
var rio_bounds = function(image) {
  // Recorte con AOI
  return image.clip(ROI);
};

//Recorte a coleccion de imagenes del rio
var S2Clipped = s2_ic_filt.map(rio_bounds);

print(S2Clipped,"Coleccion recortada");

Map.addLayer(S2Clipped,visualization, "RGB Colección recortada", false);

//Función para crear una banda llamada clorofila para
//cada una de las imágenes de nuestra colección (s2_ic_filt)

///Programar Clorofila-a usando una expresion
var addCloro = function(image) {
  var C1 = image.expression(
    '55.83*(RE1/BLUE)+35.05', {
      'RE1': image.select('B5'),
      'BLUE': image.select('B2')
    })
    .rename('CLOROFILA-A');

  return image.addBands(C1);
};

var CLOROFILA_IC = S2Clipped.map(addCloro);

print(CLOROFILA_IC.first().bandNames());

//Parametros de visualizacion

var vis= {
  min: 0,
  max:300,
  palette: [

```

```

    'midnightblue', 'blue', 'mediumblue',
    'aqua', 'lime', 'limegreen', 'yellow',
    'sandybrown', 'orange', 'crimson',
  ]
};

print (CLOROFILA_IC, 'Colección Clorofila');

//.set("system:time_start) sirve para conservar la propiedad tiempo en
cada una de las imágenes de nuestra nueva colección

Map.addLayer(CLOROFILA_IC.first().select("CLOROFILA-A"), vis, "Clorofila -
primera imagen-");

var mean = ee.Reducer.mean();
var stdDev = ee.Reducer.stdDev();
var minMax = ee.Reducer.minMax();
var mediana = ee.Reducer.median();

var combinar_reducers = mean.combine(stdDev, "", true).combine(minMax,
"", true).combine(mediana, "", true);

//////////DUDA//////////
// Utilizamos una función que se llama .reduceRegion para obtener todos
los estadísticos dentro de nuestra Area de interes (AOI)
//Esto solo me muestra los estadísticos de la primera imagen

var zonal_stats_puntos = CLOROFILA_IC.first().reduceRegion({
  reducer: combinar_reducers,
  geometry: puntos_sierpe,
  scale: 10
});

print(zonal_stats_puntos, "Estadísticos Area de Interés");

//////////map reducers to image collection

// Crear gráficos e imprimirlos en la consola
//////////

// Serie temporal de SST será el primer gráfico que vamos a crear
//Averiguar como puedo añadir la banda de interes y como renombrarla

var chart_timeSeries_puntos = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',
  regions:puntos_sierpe,
  reducer:ee.Reducer.mean(),
  scale:20,

```

```

xProperty:"system:index",
seriesProperty: "name").setOptions({
  vAxis: {title: "Clorofila"},
  title: "Variación de clorofila en los puntos de interés 2019"
});

print(chart_timeSeries_puntos, "Clorofila-a evolución temporal");

//Coordenadas marzo 2021

var pt_a=ee.Geometry.Point([-83.53328,8.85692]);
var pt_b=ee.Geometry.Point([-83.59581,8.89139]);
var pt_e=ee.Geometry.Point([-83.56864,8.890258]);
var pt_g=ee.Geometry.Point([-83.55864,8.79937]);
var pt_h=ee.Geometry.Point([-83.57702,8.86054]);
var pt_j=ee.Geometry.Point([-83.60586,8.79476]);
var pt_k=ee.Geometry.Point([-83.53191,8.83571]);
var pt_o=ee.Geometry.Point([-83.52578,8.86576]);

//Buffer

var pta = pt_a.buffer(10);
var ptb = pt_b.buffer(10);
var pte = pt_e.buffer(10);
var ptg = pt_g.buffer(10);
var pth = pt_h.buffer(10);
var ptj = pt_j.buffer(10);
var ptk = pt_k.buffer(10);
var pto = pt_o.buffer(10);

//Coordenadas marzo 2021

var chart_timeSeries_punto_a = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',
  regions:pta,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "clorofila"},
  title: "Variación de clorofila en el punto A"
  });

print(chart_timeSeries_punto_a, "Clorofila-A evolución temporal en el
punto a");

var chart_timeSeries_punto_b = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',

```

```

regions:ptb,
reducer:ee.Reducer.mean(),
scale:20,
xProperty:"system:index",
seriesProperty: "name").setOptions({
  vAxis: {title: "clorofila"},
  title: "Variación de clorofila en el punto B"
});

print(chart_timeSeries_punto_b, "Clorofila-A evolución temporal en el
punto b");

var chart_timeSeries_punto_e = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',
  regions:pte,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "clorofila"},
  title: "Variación de clorofila en el punto E"
});

print(chart_timeSeries_punto_e, "Clorofila-A evolución temporal en el
punto e");

var chart_timeSeries_punto_g = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',
  regions:ptg,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "clorofila"},
  title: "Variación de clorofila en el punto G"
});

print(chart_timeSeries_punto_g, "Clorofila-A evolución temporal en el
punto g");

var chart_timeSeries_punto_h = ui.Chart.image.seriesByRegion({
  imageCollection:CLOROFILA_IC,
  band:'CLOROFILA-A',
  regions:pth,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "clorofila"},
  title: "Variación de clorofila en el punto H"
});

```

```

    });

    print(chart_timeSeries_punto_h, "Clorofila-A evolución temporal en el
    punto h");

    var chart_timeSeries_punto_j = ui.Chart.image.seriesByRegion({
        imageCollection:CLOROFILA_IC,
        band:'CLOROFILA-A',
        regions:ptj,
        reducer:ee.Reducer.mean(),
        scale:20,
        xProperty:"system:index",
        seriesProperty: "name").setOptions({
            vAxis: {title: "clorofila"},
            title: "Variación de clorofila en el punto J"
        });

    print(chart_timeSeries_punto_j, "Clorofila-A evolución temporal en el
    punto j");

    var chart_timeSeries_punto_k = ui.Chart.image.seriesByRegion({
        imageCollection:CLOROFILA_IC,
        band:'CLOROFILA-A',
        regions:ptk,
        reducer:ee.Reducer.mean(),
        scale:20,
        xProperty:"system:index",
        seriesProperty: "name").setOptions({
            vAxis: {title: "clorofila"},
            title: "Variación de clorofila en el punto K"
        });

    print(chart_timeSeries_punto_k, "Clorofila-A evolución temporal en el
    punto k");

    var chart_timeSeries_punto_o = ui.Chart.image.seriesByRegion({
        imageCollection:CLOROFILA_IC,
        band:'CLOROFILA-A',
        regions:pto,
        reducer:ee.Reducer.mean(),
        scale:20,
        xProperty:"system:index",
        seriesProperty: "name").setOptions({
            vAxis: {title: "clorofila"},
            title: "Variación de clorofila en el punto O"
        });

    print(chart_timeSeries_punto_o, "Clorofila-A evolución temporal en el
    punto o");

```

```

//-----//
// ANIMACION //
//-----//

Map.addLayer(rectangle);
Map.centerObject(rectangle, 3);

// Seleccionar colección y banda
var collection = CLOROFILA_IC.select('CLOROFILA-A');

// Añadir la primera imagen al mapa para previsualizar
var im = ee.Image(collection.first());
Map.addLayer(im, {}, "first image");

// Visualization parameters.
var args = {
  crs: 'EPSG:5367', // CRTM05
  dimensions: '1000',
  region: rectangle,
  framesPerSecond: 1
};

//Función para etiquetar cada imagen con la fecha

var text = require('users/gena/packages:text'); // Import gena's package
which allows text overlay on image

var annotations = [
  {position: 'right', offset: '1%', margin: '1%', property: 'label',
  scale: 100} //large scale because image if of the whole world. Use
smaller scale otherwise
]

function addText(image){

  var timeStamp =
ee.Date(image.get('system:time_start')).format().slice(0,10); // get the
time stamp of each frame. This can be any string. Date, Years, Hours,
etc.
  var timeStamp = ee.String('Date: ').cat(ee.String(timeStamp));
//convert time stamp to string
  var image = image.visualize({ //convert each frame to RGB image
explicitly since it is a 1 band image
    forceRgbOutput: true,
    min: 0,
    max: 300,
    palette: ['midnightblue', 'blue', 'mediumblue', 'aqua', 'lime',
'limegreen', 'yellow', 'sandybrown', 'orange', 'crimson']
  }).set({'label':timeStamp}); // set a property called label for each
image

```

```

    var annotated = text.annotateImage(image, {}, geometry, annotations);
    // create a new image with the label overlaid using gena's package

    return annotated
  }

var collection = collection.map(addText) //add time stamp to all images

print(ui.Thumbnail(collection, args));

//Alternatively, print a URL that will produce the animation when
accessed.
print(collection.getVideoThumbURL(args));

// Print a URL that will produce the filmstrip when accessed.
print(collection.getFilmstripThumbURL(args));

```

### 8.1.1 Enlace al código

<https://code.earthengine.google.com/0fbc423197188dbf018c987fe342b475>

## 8.2 Anexo 2: Código utilizado para el modelaje de SST

```

// Función para añadir objetos al mapa
Map.addLayer(rio_sierpe.draw('navy'), {}, "Río y Laguna Sierpe", 0);

//////////////////// Colección de imágenes////////////////////////////////////

// Cargamos la función que enmascara píxeles nubosos (copiada y pegada de
EE catalogo de datos)

/**
 * Function to mask clouds using the Sentinel-2 QA band
 * @param {ee.Image} image Sentinel-2 image
 * @return {ee.Image} cloud masked Sentinel-2 image
 */
function maskS2clouds(image) {
  var qa = image.select('QA60');

  // Bits 10 and 11 are clouds and cirrus, respectively.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;

  // Both flags should be set to zero, indicating clear conditions.

```

```

var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));

return
image.updateMask(mask).divide(10000).copyProperties(image, ['system:time_s
tart']);
}
//Se declara la variable de la coleccion de imagenes y se filtra por
fecha y region de interes
var s2_ic_filt = ee.ImageCollection('COPERNICUS/S2_SR')
    .filterDate('2019-01-01','2020-01-01')
    .filterBounds(puntos_sierpe)
    // Pre-filter to get less cloudy granules.
    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',20))
    .map(maskS2clouds);

var visualization = {
  min: 0.0,
  max: 0.3,
  bands: ['B4', 'B3', 'B2'],
};

print(s2_ic_filt,'Colección de imágenes Sentinel-2 filtrado por fecha y
región');

//
Map.setCenter(-83.4746, 8.8679, 12);

//Se agrega la capa con un promedio .mean() de las imágenes
Map.addLayer(s2_ic_filt.mean(), visualization, 'RGB');

var bandas = s2_ic_filt.first().bandNames();
print (bandas, "Bandas Sentinel 2");

//////////CLIP TO COLLECTION IMAGES

// Funcion para recortar con los limites del rio
var rio_bounds = function(image) {
  // Recorte con AOI
  return image.clip(ROI);
};

//Recorte a coleccion de imagenes del rio
var S2Clipped = s2_ic_filt.map(rio_bounds);

print(S2Clipped,"Coleccion recortada");

Map.addLayer(S2Clipped,visualization, "RGB Colección recortada", false);

```

```

///Programar SST usando una expresion 542389.3484937522
222.07562205852145
var addSST = function(image) {
  var SST = image.expression(
    '-229.34 * ((GREEN/NIR) ** 3 )+ 1001.65 * ((GREEN/NIR) ** 2) - 1422.7
* (GREEN/NIR) +665.17', {
    'NIR': image.select('B8'),
    'GREEN': image.select('B3')

  }).rename('SST');

  return image.addBands(SST);
};

var SST_IC = S2Clipped.map(addSST);

print(SST_IC.first().bandNames());

print (SST_IC,'Colección Sólidos Suspendidos Totales');

//Parametros de visualizacion, el maximo y el minimo fueron elegidos
empiricamente
// como puedo probar que es mejor para la visualizacion
var vis= {
  min:-500,
  max:500,
  palette: [
    'midnightblue', 'blue', 'mediumblue',
    'aqua', 'lime', 'limegreen', 'yellow',
    'sandybrown','orange', 'crimson',
  ]
};

Map.addLayer(SST_IC.first().select("SST"),vis,"SST -primera imagen-");

var mean = ee.Reducer.mean();
var stdDev = ee.Reducer.stdDev();
var minMax = ee.Reducer.minMax();
var mediana = ee.Reducer.median();

var combinar_reducers = mean.combine(stdDev, "", true).combine(minMax,
"", true).combine(mediana, "", true);

// Estadísticos

var zonal_stats_puntos = SST_IC.first().reduceRegion({
  reducer: combinar_reducers,
  geometry: puntos_sierpe,
  scale: 10
});

print(zonal_stats_puntos, "Estadísticos Area de Interés");

```

```

//////////map reducers to image collection

// Crear gráficos e imprimirlos en la consola//
////////////////////////////////////

// Serie temporal de SST será el primer gráfico que vamos a crear

var chart_timeSeries_puntos = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band:'SST',
  regions:puntos_sierpe,
  reducer:ee.Reducer.mean(),
  scale:30,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en los puntos de interés 2019"
});

print(chart_timeSeries_puntos, "SST evolución temporal");

//Coordenadas marzo 2019

var pt_a=ee.Geometry.Point([-83.61571,8.89551]);
var pt_b=ee.Geometry.Point([-83.57098,8.88892]);
var pt_c=ee.Geometry.Point([-83.52706,8.86158]);
var pt_d=ee.Geometry.Point([-83.64279,8.7749]);
var pt_e=ee.Geometry.Point([-83.56068,8.79372]);
var pt_f=ee.Geometry.Point([-83.53346,8.82995]);
var pt_j=ee.Geometry.Point([-83.51864,8.85087]);
var pt_k=ee.Geometry.Point([-83.54977,8.85693]);
var pt_l=ee.Geometry.Point([-83.57732,8.84606]);
var pt_m=ee.Geometry.Point([-83.47217,8.85798]);
var pt_n=ee.Geometry.Point([-83.53852,8.85727]);
var pt_o=ee.Geometry.Point([-83.5065,8.85784]);

//Buffer

var pta = pt_a.buffer(5);
var ptb = pt_b.buffer(5);
var ptc = pt_c.buffer(5);
var ptd = pt_d.buffer(5);
var pte = pt_e.buffer(5);
var ptf = pt_f.buffer(5);
var ptj = pt_j.buffer(5);
var ptk = pt_k.buffer(5);
var ptl = pt_l.buffer(5);
var ptm = pt_m.buffer(5);
var ptn = pt_n.buffer(5);
var pto = pt_o.buffer(5);

```

```

var chart_timeSeries_punto_a = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:pta,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto A"
});

print(chart_timeSeries_punto_a, "SST evolución temporal en el punto a");

var chart_timeSeries_punto_b = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptb,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto B"
});

print(chart_timeSeries_punto_b, "SST evolución temporal en el punto b");

var chart_timeSeries_punto_c = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptc,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto C"
});

print(chart_timeSeries_punto_c, "SST evolución temporal en el punto c");

var chart_timeSeries_punto_d = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptd,
  reducer:ee.Reducer.mean(),
  scale:20,

```

```

    xProperty:"system:index",
    seriesProperty: "name")).setOptions({
      vAxis: {title: "SST"},
      title: "Variación de SST en el punto D"
    });

print(chart_timeSeries_punto_d, "SST evolución temporal en el punto d");

var chart_timeSeries_punto_e = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:pte,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
    vAxis: {title: "SST"},
    title: "Variación de SST en el punto E"
  });

print(chart_timeSeries_punto_e, "SST evolución temporal en el punto e");

var chart_timeSeries_punto_f = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptf,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
    vAxis: {title: "SST"},
    title: "Variación de SST en el punto F"
  });

print(chart_timeSeries_punto_f, "SST evolución temporal en el punto f");

var chart_timeSeries_punto_j = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptj,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
    vAxis: {title: "SST"},
    title: "Variación de SST en el punto J"
  });

print(chart_timeSeries_punto_j, "SST evolución temporal en el punto j");

```

```

var chart_timeSeries_punto_k = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptk,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto K"
});

print(chart_timeSeries_punto_k, "SST evolución temporal en el punto k");

var chart_timeSeries_punto_l = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptl,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto L"
});

print(chart_timeSeries_punto_l, "SST evolución temporal en el punto l");

var chart_timeSeries_punto_m = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptm,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto M"
});

print(chart_timeSeries_punto_m, "SST evolución temporal en el punto m");

var chart_timeSeries_punto_n = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:ptn,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto N"
});

```

```

print(chart_timeSeries_punto_n, "SST evolución temporal en el punto n");

var chart_timeSeries_punto_o = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:pto,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name"}).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto O"
});

print(chart_timeSeries_punto_o, "SST evolución temporal en el punto o");

//Coordenadas noviembre 2019

var pl=ee.Geometry.Point([-83.52933,8.87454]);
var pj=ee.Geometry.Point([-83.573070,8.88732]);
var pi=ee.Geometry.Point([-83.56707,8.79346]);
var ph=ee.Geometry.Point([-83.62787,8.78063]);
var pg=ee.Geometry.Point([-83.54559,8.81331]);
var pe=ee.Geometry.Point([-83.59497,8.84538]);
var pd=ee.Geometry.Point([-83.51757,8.84883]);
var pk=ee.Geometry.Point([-83.61848,8.9113]);

//Buffer
var p_l=pl.buffer(5);
var p_j=pj.buffer(5);
var p_i=pi.buffer(5);
var p_h=ph.buffer(5);
var p_g=pg.buffer(5);
var p_e=pe.buffer(5);
var p_d=pd.buffer(5);
var p_k=pk.buffer(5);

var chart_timeSeries_punto_lnov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_l,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name"}).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto L"
});

print(chart_timeSeries_punto_lnov, "SST evolución temporal en el punto L
nov");

var chart_timeSeries_punto_jnov = ui.Chart.image.seriesByRegion({

```

```

    imageCollection:SST_IC,
    band: 'SST',
    regions:p_j,
    reducer:ee.Reducer.mean(),
    scale:20,
    xProperty:"system:index",
    seriesProperty: "name").setOptions({
      vAxis: {title: "SST"},
      title: "Variación de SST en el punto J"
    });

print(chart_timeSeries_punto_jnov, "SST evolución temporal en el punto J
nov");

var chart_timeSeries_punto_inov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_i,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
    vAxis: {title: "SST"},
    title: "Variación de SST en el punto I"
  });

print(chart_timeSeries_punto_inov, "SST evolución temporal en el punto I
nov");

var chart_timeSeries_punto_hnov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_h,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name").setOptions({
    vAxis: {title: "SST"},
    title: "Variación de SST en el punto H"
  });

print(chart_timeSeries_punto_hnov, "SST evolución temporal en el punto H
nov");

var chart_timeSeries_punto_gnov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_g,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",

```

```

seriesProperty: "name")).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto G"
});

print(chart_timeSeries_punto_gnov, "SST evolución temporal en el punto G
nov");

var chart_timeSeries_punto_enov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_e,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto E"
});

print(chart_timeSeries_punto_enov, "SST evolución temporal en el punto E
nov");

var chart_timeSeries_punto_dnov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_d,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto D"
});

print(chart_timeSeries_punto_dnov, "SST evolución temporal en el punto D
nov");

var chart_timeSeries_punto_knov = ui.Chart.image.seriesByRegion({
  imageCollection:SST_IC,
  band: 'SST',
  regions:p_k,
  reducer:ee.Reducer.mean(),
  scale:20,
  xProperty:"system:index",
  seriesProperty: "name")).setOptions({
  vAxis: {title: "SST"},
  title: "Variación de SST en el punto K"
});

```

```

print(chart_timeSeries_punto_knov, "SST evolución temporal en el punto K
nov");

//-----//
//ANIMACION PRUEBA CON SCRIPT EJEMPLO//
//-----//

//Área para el encuadre
Map.addLayer(rectangle);
Map.centerObject(rectangle, 3);

// Selección de colección y banda
var collection = SST_IC.select('SST');

// Add the first image to the map, just as a preview.
var im = ee.Image(collection.first());
Map.addLayer(im, {}, "first image");

// Visualization parameters.
var args = {
  crs: 'EPSG:5367', // CRTM05
  dimensions: '1000',
  region: rectangle,
  framesPerSecond: 1
};

//Codigo para etiquetar la fecha de cada imagen

var text = require('users/gena/packages:text'); // Import gena's package
which allows text overlay on image

var annotations = [
  {position: 'right', offset: '1%', margin: '1%', property: 'label',
scale: 100} //large scale because image if of the whole world. Use
smaller scale otherwise
]

function addText(image){

  var timeStamp =
ee.Date(image.get('system:time_start')).format().slice(0,10); // get the
time stamp of each frame. This can be any string. Date, Years, Hours,
etc.
  var timeStamp = ee.String('Date: ').cat(ee.String(timeStamp));
//convert time stamp to string
  var image = image.visualize({ //convert each frame to RGB image
explicitly since it is a 1 band image
    forceRgbOutput: true,
    min: -500,
    max: 500,

```

```

        palette: ['midnightblue', 'blue', 'mediumblue', 'aqua', 'lime',
'limegreen', 'yellow','sandybrown', 'orange', 'crimson']
    }).set({'label':timeStamp}); // set a property called label for each
image

    var annotated = text.annotateImage(image, {}, geometry, annotations);
// create a new image with the label overlaid using gena's package

    return annotated
}

var collection = collection.map(addText) //add time stamp to all images

print(ui.Thumbnail(collection,args));

//Alternatively, print a URL that will produce the animation when
accessed.
print(collection.getVideoThumbURL(args));

// Print a URL that will produce the filmstrip when accessed.
print(collection.getFilmstripThumbURL(args));

```

### **8.2.1 Enlace al código de SST**

<https://code.earthengine.google.com/b527f28352994620e64ca0ceafa4843a>



Esta obra está bajo una [licencia de Creative Commons Reconocimiento-  
NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/).