

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

Aplicación de Google Earth Engine y herramientas de cómputo en la nube para el monitoreo de recursos hídricos

MATERIAL DIDÁCTICO

Que para obtener el título de

Ingeniera Geofísica

P R E S E N T A

María Isabel Celso Crescencio

ASESOR DE MATERIAL DIDÁCTICO

Dr. Saúl Arciniega Esparza



Ciudad Universitaria, Cd. Mx., 2026

PROTESTA UNIVERSITARIA DE INTEGRIDAD Y HONESTIDAD ACADÉMICA Y PROFESIONAL
(Titulación con trabajo escrito)

De conformidad con lo dispuesto en los artículos 87, fracción V, del Estatuto General, 68, primer párrafo, del Reglamento General de Estudios Universitarios y 26, fracción I, y 35 del Reglamento General de Exámenes, me comprometo en todo tiempo a honrar a la institución y a cumplir con los principios establecidos en el Código de Ética de la Universidad Nacional Autónoma de México, especialmente con los de integridad y honestidad académica.

De acuerdo con lo anterior, manifiesto que el trabajo escrito titulado APLICACION DE GOOGLE EARTH ENGINE Y HERRAMIENTAS DE COMPUTO EN LA NUBE PARA EL MONITOREO DE RECURSOS HIDRICOS. que presenté para obtener el titulo de INGENIERA GEOFÍSICO es original, de mi autoría y lo realicé con el rigor metodológico exigido por mi Entidad Académica, citando las fuentes de ideas, textos, imágenes, gráficos u otro tipo de obras empleadas para su desarrollo.

En consecuencia, acepto que la falta de cumplimiento de las disposiciones reglamentarias y normativas de la Universidad, en particular las ya referidas en el Código de Ética, llevará a la nulidad de los actos de carácter académico administrativo del proceso de titulación.

MARIA ISABEL CELSO CRESCENCIO
Número de cuenta: 313146082

Agradecimientos

A lo largo de mi formación educativa, he tenido la suerte de contar con el apoyo de personas que han contribuido a desarrollar mis fortalezas y concretar una profesión.

En primer lugar, expreso mi más sincero agradecimiento a mi asesor de material didáctico, el Dr. Saúl Arciniega Esparza, por su valiosa orientación, su rigor académico y su permanente disposición para acompañar este proceso formativo. Su interés genuino por la formación de sus estudiantes, así como su disposición para acompañar y orientar de manera constante, hicieron posible el desarrollo y culminación de este trabajo. Reconozco especialmente la paciencia y comprensión que mostró durante el tiempo que requirió su elaboración, así como la confianza depositada en mi desempeño. Su calidad humana y profesional constituye un referente valioso dentro de la vida universitaria y un ejemplo de la labor docente ejercida con responsabilidad y vocación.

A mis padres. A quienes dedico este grado, su apoyo y compromiso me permiten el privilegio de continuar aprendiendo. Su guía, inteligencia y valor fundamentan mi capacidad para lograr mis objetivos y seguir creciendo.

A mis hermanas. Su apoyo, cariño, franqueza y fraternidad me hacen sentir acompañada en cada paso y me permite acompañar.

A Tito, Silver, Ilulu, Kyo, Tonny y Piedrita.

A Marco. Su apoyo y amistad hacen la diferencia todos los días.

A mis amigos. Jhynka, María, Ricardo.

Índice general

Introducción……..…1

Objetivo general……...…3

Objetivos particulares…….…..3

Marco teórico……....4

Principios de la percepción remota……....4

Tipos de órbitas……...….6

Tipos de sensores…….……..6

Resolución espectral……...8

Resolución espacial…….8

Resolución Temporal……...9

Resolución radiométrica……...…….....….10

Radiancia y reflectancia……..……..……10

Índices espectrales……..……..…….12

Sensores gravimétricos satelitales (GRACE)……..……...….13

Tipos de productos globales…….……...….17

Percepción remota…….……17

Reanálisis…….……..……18

Productos globales……18

Herramientas utilizadas…….……..19

Google Earth Engine……..19

Python y entornos virtuales…….20

Principales librerías……...21

Jupyter Lab…….21

Pandas…….……21

Geemap…….……..21

Panel…….……...22

Desarrollo de las herramientas computacionales……..23

Repositorio……..23

Análisis espacio-temporal de variables hidrológicas/hidrogeológicas en acuíferos……..23

Análisis de la variación temporal del área inundada en embalses de presas con imágenes Landsat……..…28

Ejemplos de aplicación……..36

Caracterización del acuífero “1508” Cuautitlán-Pachuca……36

Variación del almacenamiento de agua en la presa el Cuchillo, Nuevo León…….....39

Conclusiones……..…….....41

Referencias……...……..41

Índice de figuras

Figura 1. Las dos componentes oscilatorias de la radiación electromagnética y propagación de la onda. Fuente: modificado de Bakker et al. (2009)……..……..4

Figura 2. Variaciones de la longitud de onda en el espectro electromagnético y espectro de luz visible. Fuente: modificado de Ronan, (2008)……..5

Figura 3. Sensores pasivos y activos. Fuente: NASA ARSET (2023)……..7

Figura 4. Distribución y rango de longitudes captadas por los sensores activos y pasivos. Fuente: modificado de Bakker et. al. (2009)…….7

Figura 5. Comparación de resolución espectral entre la misión Landsat 7-8 y Sentinel 2. Fuente: modificado de EROS (2019)……...……8

Figura 6. Comparación de la resolución espacial de las misiones Landsat 8 (30 m), Sentinel 2 (10 m), y Planet (3 m). Fuente: tomada de McCabe et al. (2017)……...9

Figura 7. Interferencia en el viaje de la energía captada por un sensor satelital. Fuente: modificada de MathWorks (2024)……..11

Figura 8. Curva de reflectancia espectral idealizada de una vegetación sana. Fuente: modificada de Bakker et. al. (2009)…….…13

Figura 9. Comparación entre el esferoide y el geoide. Fuente: modificada de Telford et al. (1990).……..…….15

Figura 10. Concepto de la misión GRACE. Fuente: modificada de Baur et. al. (2007).…….……17

Figura 11. Mapa de los 653 acuíferos administrativos en México.…….…….24

Figura 12. Importación de librerías y módulos necesarios para la ejecución del programa…….……..24

Figura 13. Diccionario de colecciones. Incluye: variable a consultar, unidad de medida, factor de conversión y escala temporal……...……..25

Figura 14. Herramientas interactivas para la consulta y descarga de series de tiempo. 1. Seleccionar acuífero. 2. Variable a descargar. 3. Rango de tiempo……..…25

Figura 15. Código para la función get_data()……..27

Figura 16. Código para la función collection_timeserie()…….……28

Figura 17. Salida a pantalla de la herramienta de monitoreo……..29

Figura 18. Importación de librerías y módulos necesarios para la ejecución del programa……...30

Figura 19. Mapa de las presas monitoreadas……..…….....31

Figura 20. Importación de los archivos necesarios para la construcción del mapa…..……...31

Figura 21. Herramientas interactivas para la consulta y descarga de series de tiempo.
1. Presa a consultar. 2. Filtrado de datos. 3. Descargar serie……32

Figura 22. Código para la función get_data()…….33

Figura 23. Código para la función compute_flooded_area……..33

Figura 24. Código para la función gee_ts_to_serie()……33

Figura 25. Salida a pantalla de la herramienta de monitoreo……..…34

Figura 26. Resultado del algoritmo del filtro aplicado a los datos.
1. Gráfica de datos originales. 2. Gráfica de datos filtrados ……...35

Figura 27. Grafica de la serie de tiempo diaria de la variable de precipitación
para el acuífero 1508……..……...…36

Figura 28. Comportamiento de la gráfica interactiva de la de la Figura 25……...37

Figura 29. Grafica de la serie de tiempo mensual de la variable de
precipitación para el acuífero 1508……..……..……..37

Figura 30. Grafica de la serie de tiempo mensual de la variable de
humedad del suelo para el acuífero 1508…….……..38

Figura 31. Grafica de la serie de tiempo mensual de la variable de
temperatura máxima para el acuífero.……...……..…38

Figura 32. Grafica de la serie de tiempo mensual de la variable de
almacenamiento de agua subterránea para el acuífero 1508……..38

Figura 33. Grafica de la serie de tiempo mensual de la variable de índice
de vegetación normalizada para el acuífero 1508…….……...…39

Figura 34. Grafica de la serie de tiempo del valor de área inundada de la presa
2689……...39

Figura 35. Grafica filtrada de la serie de tiempo y representación
geográfica del área inundada de la presa 2689..……...40

Índice de tablas

Tabla 1. Rango de longitud de onda de ondas electromagnéticas……5

Tabla 2. Variables hidrológicas e hidrogeológicas……..…26

Resumen

Con el propósito de monitorear variables hidrológicas e hidrogeológicas en los acuíferos de México, así como la variación del área inundada en los embalses en las principales presas del país, se planteó como objetivo desarrollar material interactivo orientado a integrar datos derivados de percepción remota a través de la plataforma Google Earth Engine. A fin de lograr dicho propósito, se utilizaron productos globales y datos de reanálisis, integrados mediante la plataforma de Google Earth Engine y entornos de programación de Pyhton, apoyados en librerías especializadas y entornos interactivos como Jupyter Lab. Estas herramientas se organizaron en un repositorio que facilitó el análisis espacio-temporal de variables hidro-climatológicas en acuíferos y la evaluación de la variación del área inundada en embalses de las principales presas del país a partir de imágenes Landsat.

Los resultados obtenidos demostraron la eficacia de las herramientas para monitorear el comportamiento temporal de variables hidrogeológicas, detectar cambios en el almacenamiento de agua y evaluar el impacto de periodos de sequía en la disponibilidad hídrica. En conjunto, el trabajo cumplió con los objetivos planteados y aportó evidencia técnica para la gestión sostenible de los recursos naturales, destacando la importancia de integrar datos satelitales con información de campo para fortalecer la toma de decisiones en materia de planeación y conservación ambiental.

Introducción

Los recursos naturales son imprescindibles para satisfacer las necesidades humanas, por lo que la gestión sostenible de éstos es fundamental para garantizar el desarrollo de las generaciones futuras. El agua superficial y subterránea son recursos naturales cuya demanda ha incrementado en las últimas décadas, y en conjunto con la variabilidad climática y la recurrencia de sequías, ha disminuido su disponibilidad y calidad (Ndehedehe, 2022).

En este contexto, el monitoreo de los recursos hídricos se convierte en una herramienta fundamental para comprender su distribución espacial y temporal, identificar impactos negativos y respaldar la toma de decisiones orientadas a su gestión sostenible. Sin embargo, el monitoreo de los recursos naturales enfrenta diversos desafíos, entre ellos los elevados costos asociados a la adquisición, instalación y mantenimiento de los instrumentos de medición. Además, algunos recursos, como el agua, presentan una alta variabilidad tanto temporal como espacial (Su *et al*., 2011). A esta situación se suma la reducción de estaciones y puntos de monitoreo observada en países como México durante los últimos años (CONAGUA, 2021).

México cuenta con varios sistemas de monitoreo de recursos naturales, como el Sistema de Monitoreo de Biodiversidad y Degradación (SMBD), el Sistema Nacional de Monitoreo Forestal (SNMF) y el Sistema de Información Hidrológica (SIH). Estos portales presentan información de distintas fuentes (estaciones de monitoreo, sensores, información espacial digitalizada), sin embargo, los portales no son intuitivos, no permiten consultar información de forma interactiva, y en algunos casos, la información no se encuentra actualizada, presenta huecos en los registros o no se puede descargar. Este tipo de situaciones complica la integración de la información para su análisis e interpretación.

La percepción remota satelital brinda la posibilidad de obtener datos de la superficie terrestre y los cuerpos de agua desde el espacio. Los sensores implementados en estos satélites son capaces de detectar y registrar la energía reflejada por cada punto de la superficie, proporcionando imágenes continuas en el tiempo y espacio. Estas imágenes derivadas de satélites permiten identificar colores, formas, cobertura del suelo y temperaturas de la zona observada (Phiri *et al*., 2020; Orynbaikyzy *et al*., 2020), así como monitorear la calidad del agua (Ngamile *et al*., 2025) y variables hidroclimatológicas como precipitación, evaporación, humedad del suelo, entre otras (Ndehedehe, 2022; Sheffield *et al*., 2018; McCabe *et al*., 2017; Su *et al*., 2011).

En las últimas décadas ha sido posible monitorear la mayoría de los procesos del ciclo hidrológico a escala planetaria con información satelital, lo que ha contribuido de forma

sustancial al monitoreo y evaluación de los recursos hídricos e impulsando la observación terrestre hacia una ciencia intensiva en datos (Chen y Wang, 2018; McCabe *et al*., 2017). Sin embargo, esto ha ocasionado que se requieran herramientas más sofisticadas y mayor capacidad de almacenamiento para trabajar con toda esa información.

Una de las plataformas que ha ganado liderazgo en el análisis de datos derivados de percepción remota es Google Earth Engine, una plataforma desarrollada por Google Inc. que cuenta con un extenso catálogo de información derivada de diferentes misiones satelitales, además, permite el procesamiento de información en la plataforma misma o usando una API para el lenguaje de programación Java o Python (Gorelick, 2012). Esta plataforma permite el procesamiento de información de manera remota y mediante cómputo en la nube simplifica el procesamiento de datos satelitales a gran escala, lo que hace posible realizar el monitoreo de recursos naturales a escala regional, nacional o planetaria desde cualquier lugar con acceso a internet.

Con el fin de aprovechar la información y las tecnologías satelitales disponibles, en este trabajo se presenta el desarrollo y la aplicación de herramientas de monitoreo basadas en datos satelitales para la evaluación de variables hidrológicas e hidrogeológicas en los acuíferos de México; así como para el monitoreo de la variación del área inundada en los embalses en las principales presas del país.

Como resultado, se desarrollan dos herramientas computacionales fundamentadas basadas en Google Earth Engine, las cuales permiten evaluar la disponibilidad de agua, dar seguimiento a las sequias, identificar zonas de extracción intensiva de los recursos hídricos, entre otras aplicaciones. Estas herramientas constituyen un apoyo para la gestión y la toma de decisiones en materia de recursos hídricos, además de servir como recursos para la educación y divulgación científica.

Objetivo general

Desarrollar material interactivo que integre datos derivados de percepción remota utilizando Google Earth Engine para el análisis de recursos hídricos en México.

Objetivos particulares

- Desarrollar una herramienta de monitoreo de variables hidrológicas e hidrogeológicas en los acuíferos de México.
- Desarrollar una herramienta de monitoreo de la variación del área inundada en los embalses en las principales presas del país.
- Aplicar las herramientas de monitoreo en casos de estudio.

Marco teórico

Principios de percepción remota

La percepción remota satelital ha evolucionado en las últimas décadas gracias a los avances en la ciencia y tecnología, permitiendo monitorear la superficie terrestre y varios procesos climatológicos e hidrológicos a gran resolución espacial y temporal y, en algunos casos, en tiempo casi real (McCabe *et al*., 2017).

El principio fundamental de la percepción remota se basa en analizar cómo las ondas de energía electromagnética (o radiación electromagnética) se absorben y reflejan en distintos objetos (NASA, 2024). Esta energía se propaga en un campo eléctrico y un campo magnético ortogonales entre sí (Figura 1), cuyas ondas se caracterizan por sus frecuencias y longitudes de onda, relacionadas a partir de la siguiente expresión:

$$c = f\lambda$$

donde:

$c =$ velocidad

$f =$ frecuencia

$\lambda =$ longitud de onda

De tal manera que la energía de la longitud de la onda corta está asociada a una alta frecuencia y una mayor energía, mientras que las longitudes de onda mayores tienen menor energía.

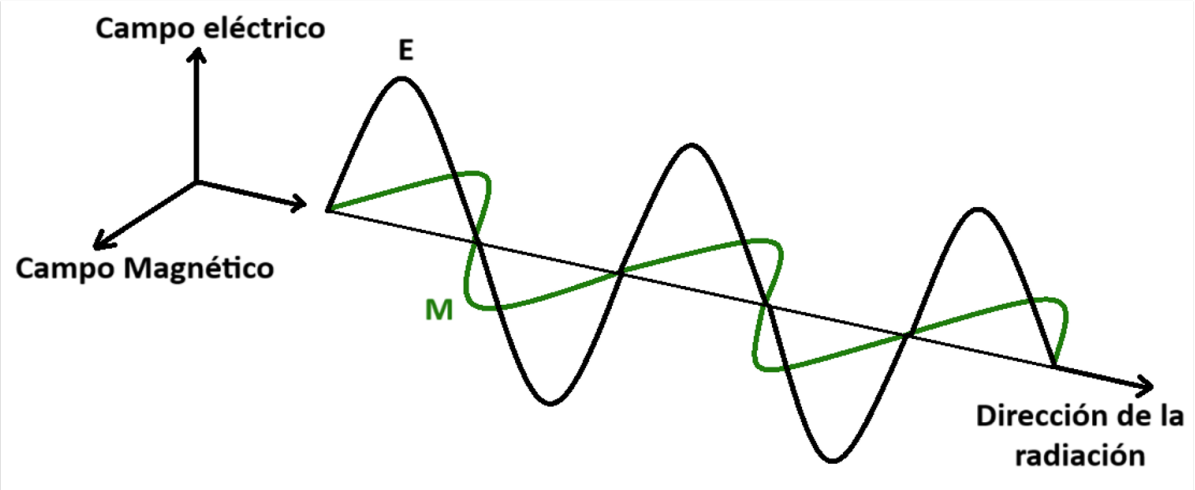


Figura 1. Las dos componentes oscilatorias de la radiación electromagnética y propagación de la onda. Fuente: modificado de Bakker et al. (2009).

El conjunto continuo e infinito de todas las longitudes de onda de la energía se conoce como el espectro electromagnético, en el cual existen clasificaciones como: rayos gamma, rayos X, ultravioleta, luz visible, infrarrojo, microondas y ondas de radio (Figura 2). Los humanos, por ejemplo, sólo tenemos la capacidad de detectar con nuestros ojos la radiación electromagnética comprendida en el rango aproximado de longitudes de onda de 400 y 700 nanómetros (Tabla 1), denominado espectro de luz visible que abarca de la radiación ultravioleta hasta la radiación infrarroja (Khorram *et al*., 2016).

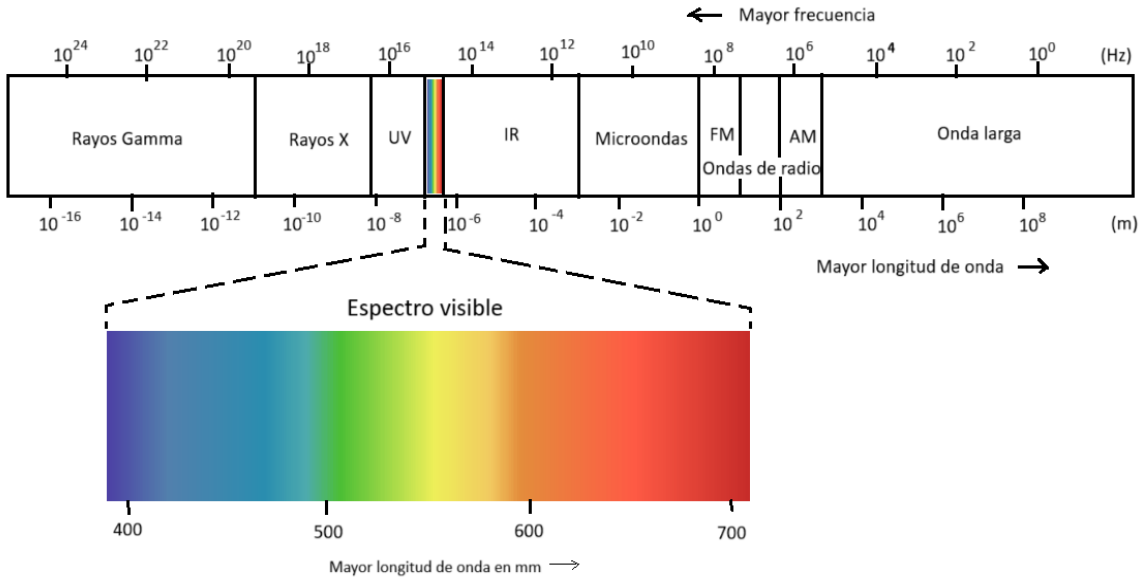


Figura 2. Variaciones de la longitud de onda en el espectro electromagnético y espectro de luz visible. Fuente: modificado de Ronan, (2008).

Tabla 1. Rango de longitud de onda de ondas electromagnéticas

Espectro electromagnético	**Intervalo de longitud de onda (m)**
Ondas de radio	$10^4 - 0.1$
Microondas	$0.3 - 10^{-4}$
Ondas infrarrojas	$10^{-3} - 7 \times 10^{-7}$
Luz visible	$7 \times 10^{-7} - 4 \times 10^{-7}$
Ondas ultravioletas	$4 \times 10^{-7} - 6 \times 10^{-10}$
Rayos X	$10^{-8} - 10^{-12}$
Rayos gamma	$10^{-10} - 10^{-14}$

En el área de la percepción remota satelital, el monitoreo de objetos en la superficie terrestre depende de diferentes factores: tipo de órbita, fuente de energía, resolución espectral, resolución espacial, resolución temporal, resolución radiométrica, entre otras.

Las imágenes satelitales están constituidas por múltiples bandas espectrales, cada una de las cuales registra información asociada con distintas características de la energía electromagnética emitida o reflejada por la superficie terrestre. Esta composición multiespectral permite obtener una gran cantidad de información a partir de una misma imagen y facilita el análisis de diversas características de la superficie terrestre. No obstante, el procesamiento y análisis de grandes volúmenes de imágenes, especialmente cuando se consideran series temporales extensas, demanda una elevada capacidad de procesamiento y almacenamiento, lo que puede representar una limitación para su manejo mediante equipos convencionales.

Tipos de orbitas

Existen órbitas predeterminadas para que los satélites orbiten alrededor de la Tierra. Estas órbitas se clasifican en función de la altitud orbital, es decir, la distancia desde la superficie de la Tierra, y la aplicación de la misión satelital definirán el tipo de órbita a utilizar, siendo las más comunes (Sergieieva, 2023; NASA ARSET, 2023):

- Órbita geoestacionaria (GEO): los satélites con esta órbita se colocan normalmente a ~36,000 km de la Tierra con el fin de obtener varias observaciones de una misma área durante el día. Estos satélites tienen una cobertura limitada y suelen implementarse en meteorología. En este tipo de órbitas el satélite se mueve a la misma velocidad angular de la Tierra, por lo que siempre observa la misma área de la superficie.

- Órbita terrestre baja (LEO): se encuentran a una altitud de entre los 160 y 1,500 km de la Tierra. Los satélites con esta configuración suelen tener una alta resolución espacial y orbitan alrededor de la Tierra en 90 minutos (NASA, 2010) con coberturas casi globales. La órbita LEO puede además dividirse como polar (si pasa por los polos), o no polar (no pasa por los polos).

- Órbita Heliosincrona (SSO): se suele ubicar a altitudes de entre 600 y 800 km de la Tierra. Tiene una cobertura global y se encuentran en sincronía con el sol, por lo que el satélite revisita el mismo lugar a la misma hora del día.

Tipos de sensores

Los satélites pueden tener incorporados sensores pasivos o activos (Figura 3), en donde los primeros aprovechan la energía provista por la radiación del sol que incide sobre la superficie terrestre para detectar variaciones espaciales y temporales de energía reflejada por los objetos, mientras que los sensores activos generan su propia energía, siendo la tecnología Lidar y los radares ejemplos de sensores activos.

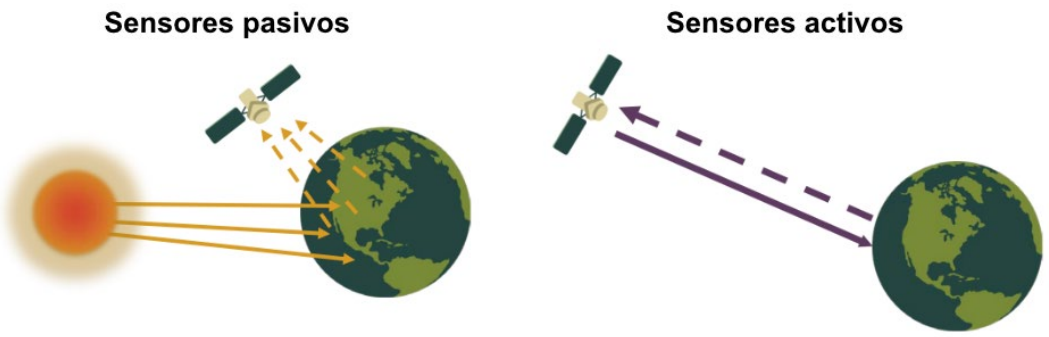


Figura 3. Sensores pasivos y activos. Fuente: NASA ARSET (2023).

Los sensores pasivos registran gran variedad de longitudes de onda debido a que la energía es proporcionada por el sol, por lo que deben orbitar siguiendo la luz del día y se ven afectados por las malas condiciones atmosféricas. Los sensores activos registran longitudes de onda dentro del rango de las microondas principalmente (Figura 4) debido a la energía limitada que puede emitir el sensor, es capaz de proporcionar datos a toda hora y ante inclemencias climáticas.

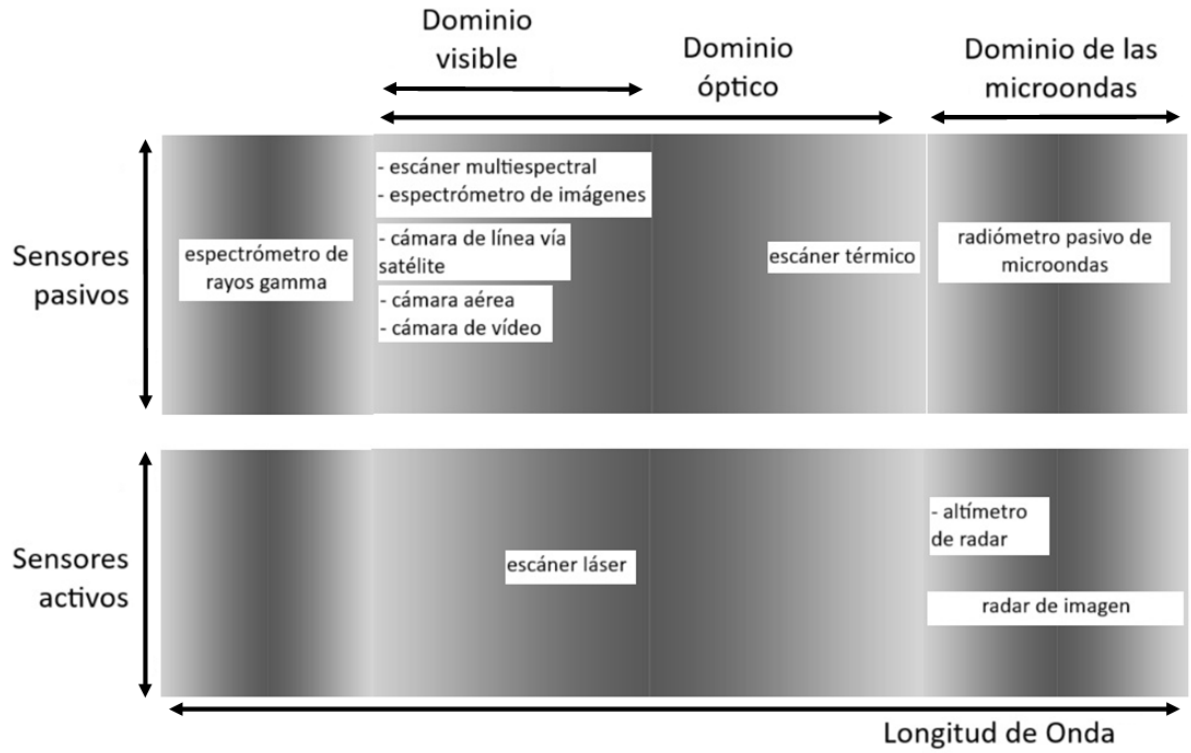


Figura 4. Distribución y rango de longitudes captadas por los sensores activos y pasivos. Fuente: modificado de Bakker et. al. (2009).

Resolución espectral

Los satélites pueden traer incorporados uno o más sensores para detectar diferentes rangos o anchos de banda de longitud de onda, lo cual se le conoce como resolución espectral. A mayor resolución espectral, más angosta será el ancho de la banda asociada a un rango de longitud de onda (Figura 5). Por lo general, una misión satelital puede cubrir diferentes bandas espectrales, de tal manera que aquellas que cubren de 3 a 10 bandas se les conoce como multiespectrales, mientras que si cubren cientos o más bandas se les conoce como hiperespectrales.

Existen aplicaciones específicas de cada longitud de onda dentro de las geociencias y otras áreas para detectar propiedades de los objetos (Ramírez-Arias, 2019; McCabe *et al*., 2017; Khorram *et al*., 2016). Las ondas de radio son comunes en sistemas de comunicación de radio y televisión; las microondas son adecuadas para los sistemas de radar que se usan en la navegación aérea y para el estudio de las propiedades atómicas y moleculares de la materia; los rayos X se usan como herramienta de diagnóstico en medicina.

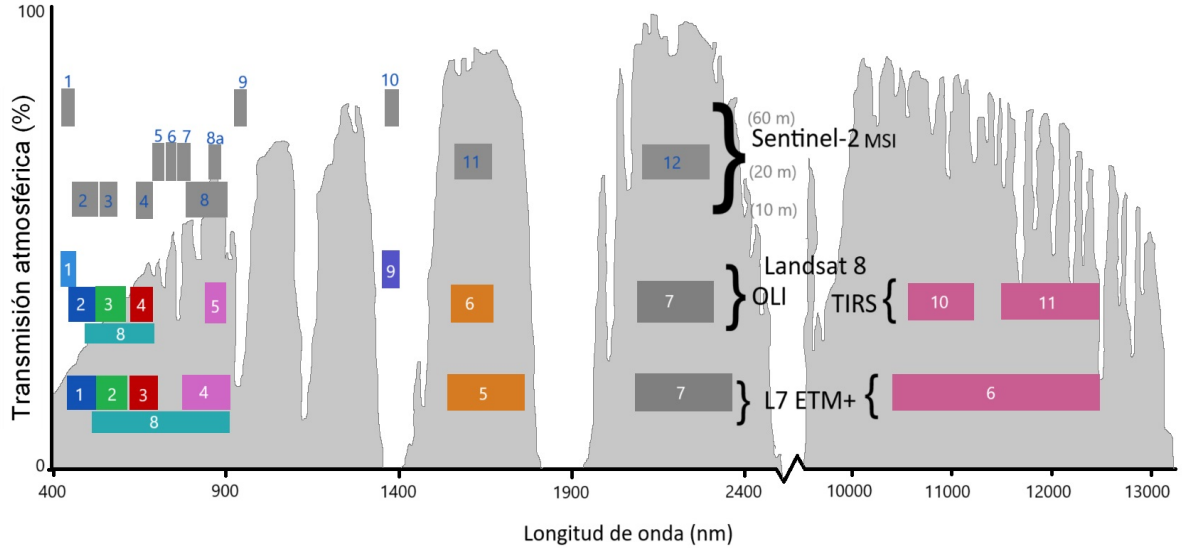


Figura 5. Comparación de resolución espectral entre la misión Landsat 7-8 y Sentinel 2. Fuente: modificado de EROS (2019).

Resolución espacial

La resolución espacial se refiere, de manera simplificada, al tamaño del píxel de la imagen, correspondiendo al ancho o alto del píxel, que en la mayoría de los casos los pixeles son cuadrados con el mismo ancho y alto. Cuando se requiere observar objetos o patrones en la superficie terrestre con detalle se necesita una mayor resolución espacial, es decir, un tamaño de píxel pequeño que permita resaltar dichas características. Por el contrario, una menor resolución espacial hace referencia a pixeles de mayor tamaño. La resolución espacial está relacionada con la órbita del satélite y con el tipo de sensor, pero también con el objetivo de la

misión satelital, por lo que encontraremos misiones satelitales con resoluciones de unos cuantos metros hasta decenas de kilómetros. En la Figura 6 se presenta una comparación de la resolución espacial de las misiones Landsat 8 y Sentinel 2, las cuales son misiones satelitales de acceso gratuito (McCabe *et al*., 2017). Actualmente existen imágenes satelitales de muy alta resolución con tamaños de pixeles menores a los 3 m, aunque estos productos no suelen ser de acceso gratuito y requieren de algún proveedor, como es el caso de las imágenes de la empresa Planet.

No se debe confundir la resolución espacial con la extensión espacial. Aunque ambos conceptos están relacionados, la extensión espacial se refiere al área total cubierta por una imagen satelital, mientras que la resolución espacial indica el tamaño del área terrestre representada por cada píxel de la imagen. En general, las imágenes con alta resolución espacial suelen tener una menor extensión espacial, ya que esto ayuda a limitar el volumen de datos generados y los requisitos de almacenamiento y procesamiento. Po esta razón, las imágenes satelitales que cubren toda la superficie terrestre suelen presentar resoluciones espaciales de varios kilómetros por píxel. En cambio, las imágenes con resoluciones espaciales de pocos metros o incluso centímetros cubren áreas más reducidas, por lo que se necesitan múltiples imágenes para representa regiones extensas.

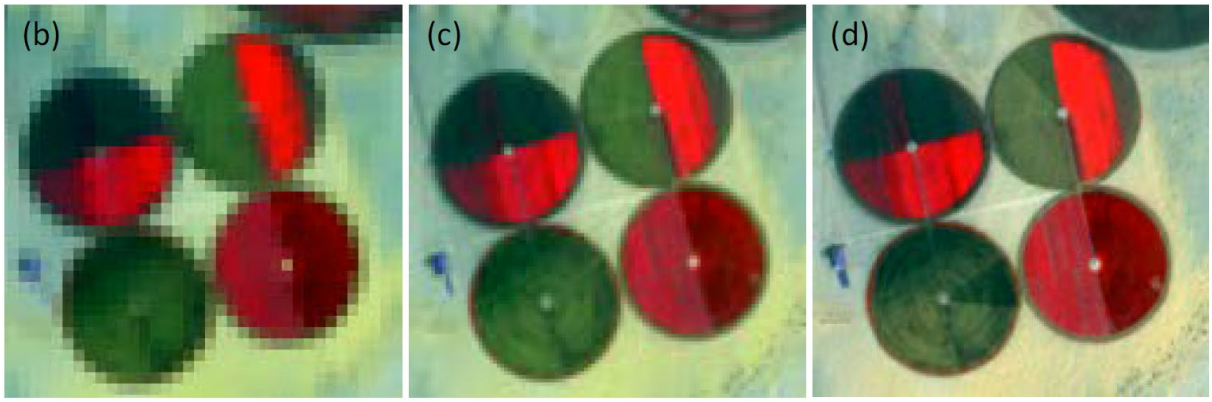


Figura 6. Comparación de la resolución espacial de las misiones Landsat 8 (30 m), Sentinel 2 (10 m), y Planet (3 m). Fuente: tomada de McCabe et al. (2017).

Resolución temporal

La resolución temporal hace referencia al tiempo que tarda un satélite en completar el recorrido de su órbita para observar un mismo sitio, por lo que también se le conoce como tiempo de revisita. Esta resolución temporal puede ir de un par de días o semanas para misiones satelitales de acceso gratuito (como Landsat y Sentinel), hasta 1 o 2 días para satélites comerciales (NASA ARSET, 2023; McCabe *et al*., 2017). Por otro lado, existen combinaciones de datos satelitales y modelos que implementan estos datos satelitales para generar bases de

datos a escalas subdiarias (McCabe *et al*., 2017). Esta resolución depende de la órbita y del barrido de la imagen (del ancho de la extensión espacial), entre otros.

Resolución radiométrica

Este tipo de resolución está asociada con la capacidad de los sensores a detectar variaciones pequeñas en la energía que perciben, por lo que una mayor resolución radiométrica permite discriminar diferencias en la energía (Khorram *et al*., 2016). La resolución radiométrica se mide en la cantidad de números con los que se representa la observación, por lo que un sensor de 6-bits (64 niveles) tiene una menor resolución radiométrica que un sensor de 12-bits (4,096 niveles).

Radiancia y reflectancia

Los sensores de los satélites están diseñados para detectar rangos de longitud de onda de la energía electromagnética, con lo cual podemos analizar diferentes propiedades de un objeto. Sin embargo, la información capturada por los sensores en los satélites debes ser corregida antes de ser analizada.

Para entender las propiedades de un objeto mediante la percepción remota se debe analizar la cantidad de energía que este es capaz de reflejar, conocida como la reflectancia. Esta reflectancia se suele medir en porcentaje respecto a la cantidad total de energía que incide sobre el objeto (NASA ARSET, 2023; Khorram *et al*., 2016). Los sensores miden la radiancia, que corresponde a la energía en dirección al sensor, la cual incluye una parte de la energía reflejada por la superficie u objeto de interés, así como la energía desviada por las partículas en la atmósfera y reflejada por otros objetos (Figura 7).

La radiancia a su vez depende de la irradiancia, ésta es la magnitud que describe la energía electromagnética que llega a un cuerpo a través del espacio procedente de otro que la emite, el cual sería la fuente. En este factor influye la inclinación de los rayos de la fuente sobre el área en la superficie (Khorram *et al*., 2016).

La reflectancia es la proporción entre irradiancia y radiancia del área en la superficie, es un valor característico del material dado por:

$$\rho_h = \frac{\pi L}{E}$$

donde:

$\rho_h =$ reflectancia

$E =$ irradiancia que llega a la superficie terrestre procedente de la fuente de energía

L = parte de la irradiancia que abandona la Tierra como radiancia

Valores de reflectancia próximos a cero denota objetos intrínsecamente muy oscuros, mientras que valores próximos a la unidad o al 100% significa objetos muy claros o brillantes.

La propagación de la energía depende del medio de transmisión, además de que, en la superficie terrestre se ve afectada por partículas en la atmósfera, lluvia, nieve, calor, vegetación, rugosidad de los objetos, entre otros (Khorram *et al*., 2016).

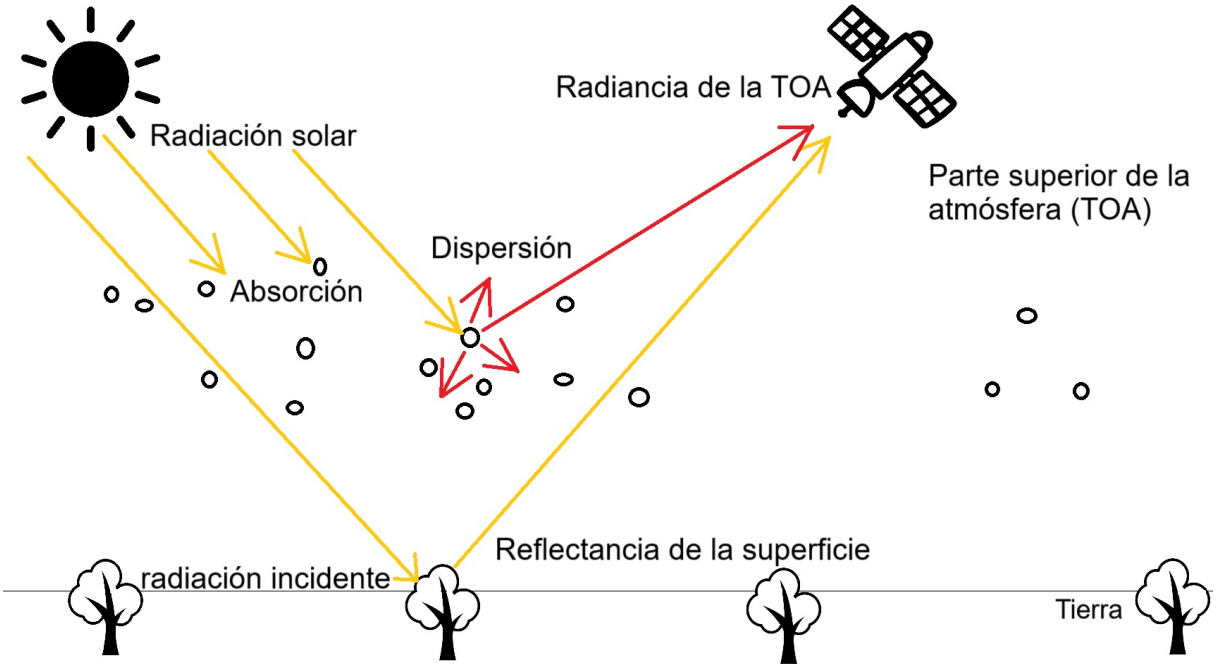


Figura 7. Interferencia en el viaje de la energía captada por un sensor satelital. Fuente: modificada de MathWorks (2024).

Para convertir la radiancia a reflectancia, existen distintos procesos de corrección que es necesario realizar sobre la imagen digital proporcionada por el sensor (MathWorks, 2024):

- Calibración geométrica: tiene como objetivo corregir las distorsiones espaciales de los píxeles al pasar a una perspectiva ortográfica, donde originalmente tienen una perspectiva cónica. Además, se incluye en el proceso cualquier cambio de escala o zoom, giros y desplazamiento sobre la imagen que se basa en puntos de control fácilmente identificables sobre la imagen cuyas coordenadas finales se conocen.

- Corrección radiométrica: permite corregir los valores de los pixeles de una imagen para obtener valores de intensidades homogéneas, reduciendo la presencia de valores de pixeles afectados por errores en la captura de datos, movimiento del sensor, o interferencia atmosférica.

- Corrección atmosférica: la energía captada por los sensores satelitales se ve afectada por la dispersión y absorción de energía en la atmósfera (Figura 7). A esta energía se le conoce como reflectancia en el tope de la atmósfera (TOA, por sus siglas en inglés), y afecta principalmente a la energía de onda corta (longitudes de onda menores a la luz verde). Existen distintos algoritmos que no se abordan a detalle en este trabajo, pero que permiten remover la interacción del sensor con la atmósfera. El resultado de esta corrección se le conoce como reflectancia en la superficie, la cual es el valor cercano a la reflectancia real del objeto medida con un espectrómetro en campo.

Las correcciones descritas anteriormente representan diferentes niveles de procesamiento que se deben aplicar a los datos recolectados por los sensores de los satélites, siendo los Niveles 0 y 1 los que suelen representar a los datos crudos y que no suelen tener alguna utilidad práctica (NASA ARSET, 2023). El Nivel 2 suele corresponder a datos del Nivel 1 convertidos a alguna cantidad geofísica, mientras que los datos de Nivel 3 son datos a los cuales se les han aplicado la mayoría de las correcciones. Niveles mayores de procesamiento suelen ser resultados de algoritmos especializados para obtener otras variables más allá de la reflectancia.

Índices espectrales

Las porciones del espectro electromagnético brindarán información diferente de la superficie de la Tierra. Podemos usar el color para discriminar objetos, así como estimar su temperatura, un objeto es “verde” cuando la longitud de onda del espectro electromagnético reflejada por ese objeto es de 500 nanómetros, en consecuencia, la reflexión del color azul y rojo es comparativamente menor. El infrarrojo cercano, comprendido en el rango de longitud de onda mayor al color rojo pero menor a infrarrojo medio, proporciona mayor reflectancia ante la vegetación, a su vez depende del tipo de hoja y estructura celular que posea la planta (Bakker *et al*., 2009).

El Índice de Vegetación de Diferencia Normalizada, NDVI por sus siglas en inglés, es una propuesta de análisis multiespectral y actualmente uno de los más recurrentes en investigaciones científicas (Tucker, 1979). Se basa en la relación entre la reflectancia en dos regiones del espectro electromagnético, luz roja e infrarroja, esto es que, a valores bajos de luz reflejada en el color rojo, combinados con alta reflexión en el infrarrojo, indican una mayor actividad fotosintética o cantidad y densidad de plantas verdes (Figura 8). El NDVI, se obtiene al calcular la razón entre la resta de los valores de las bandas infrarrojo cercano (NIR) y roja y la suma de estos:

$$NDVI = \frac{NIR - R}{NIR + R}$$

Los valores de este índice fluctúan en el intervalo $[-1, 1]$.

Existe un gran número de índices que se pueden estimar a partir de los valores de reflectancia además del NDVI, como el Índice de Agua de Diferencia Normalizada (NDWI por sus siglas en inglés), el cual es sensible a los cambios en el contenido de agua en el suelo y en la cubierta vegetal ya que la dispersión de la energía por la cubierta vegetal aumenta la débil absorción de agua líquida. Para el cálculo de este índice, la banda roja es sustituida por la banda de infrarrojos de onda corta (SWIR), la cual presenta una longitud de onda mayor, lo que implica menor energía, pero mayor capacidad de penetración:

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$$

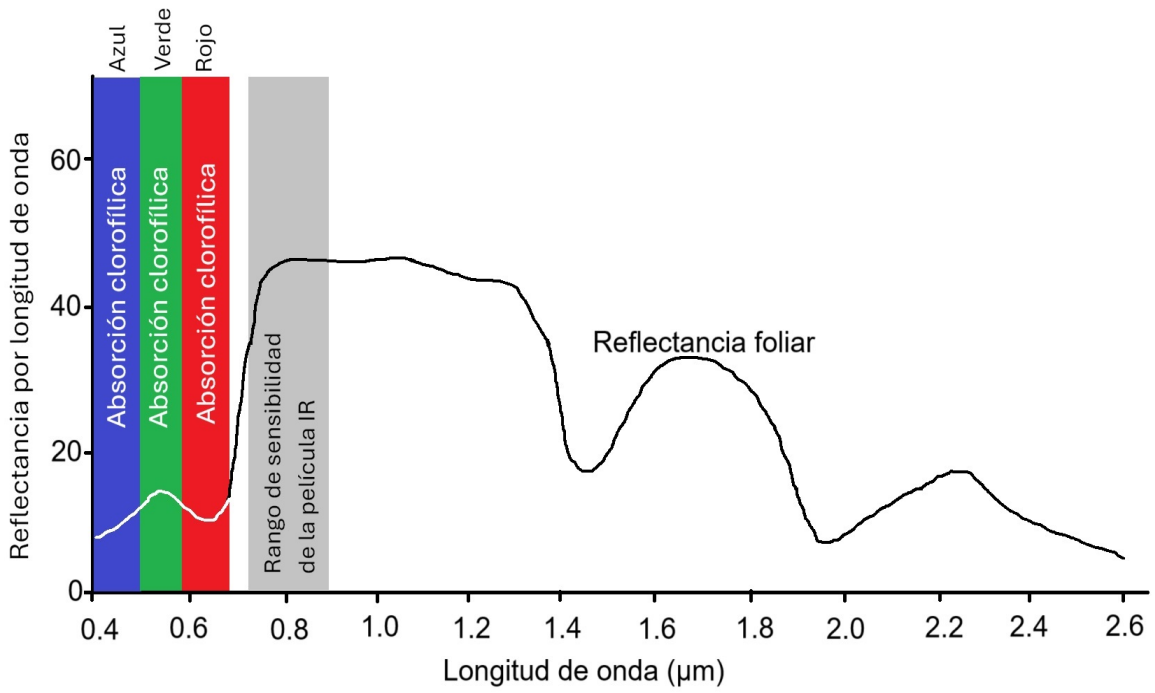


Figura 8. Curva de reflectancia espectral idealizada de una vegetación sana. Fuente: modificada de Bakker et. al. (2009).

Sensores gravimétricos satelitales (GRACE)

Un ámbito complementario dentro de la percepción remota es el análisis del campo gravimétrico. La gravedad es una de las fuerzas de la naturaleza relacionada con la atracción entre todas las masas. Su medición, denominada gravimetría, comprende el estudio de las variaciones del campo gravitatorio terrestre ocasionadas por los contrastes de densidad en la corteza (Telford et al., 1990).

La ley de gravitación universal de Newton expresa que la fuerza entre dos partículas de masas m_1 y m_2 es directamente proporcional al producto de las masas e inversamente proporcional al cuadrado de la distancia entre sus centros (Serway, 2009):

$$\vec{F} = \gamma \left(\frac{m_1 m_2}{r^2}\right) \overrightarrow{r_1}$$

donde:

$\vec{F}$ = fuerza sobre m_2

$\overrightarrow{r_1}$ = vector unitario dirigido desde m_2 hacia m_1

r = distancia entre m_1 y m_2

γ = constante gravitacional universal

En este contexto, el potencial gravitatorio describe como varia la atracción gravitacional en distintos puntos del espacio debido a la distribución de masas. La región del espacio en la cual una masa m_1 ejerce una fuerza de atracción sobre otros cuerpos con masa se denomina campo gravitacional; en particular, la acción de la gravedad que mantiene a los objetos ligados al planeta y que regula fenómenos como el movimiento orbital de los satélites, la caída libre y la dinámica de fluidos internos se denomina campo gravitacional terrestre (Salas, 2017).

La magnitud de la gravedad depende de cinco factores: latitud, altitud, topografía del terreno circundante, mareas terrestres y las variaciones de densidad en la corteza. Dado que la Tierra no es una esfera perfectamente homogénea, la aceleración gravitacional no es constante en toda su superficie, por lo cual, para determinar la forma de la Tierra se describen dos superficies (Telford et al., 1990) (Figura 9):

- Esferoide de referencia: es un elipsoide achatado que se aproxima a la superficie del nivel medio del mar, una vez eliminada la masa terrestre que se encuentra por encima de ella.
- Geoide: definido como el nivel medio del mar sobre los océanos y sobre la superficie del agua del mar que se encontraría en los canales si estos atravesaran las masas continentales.

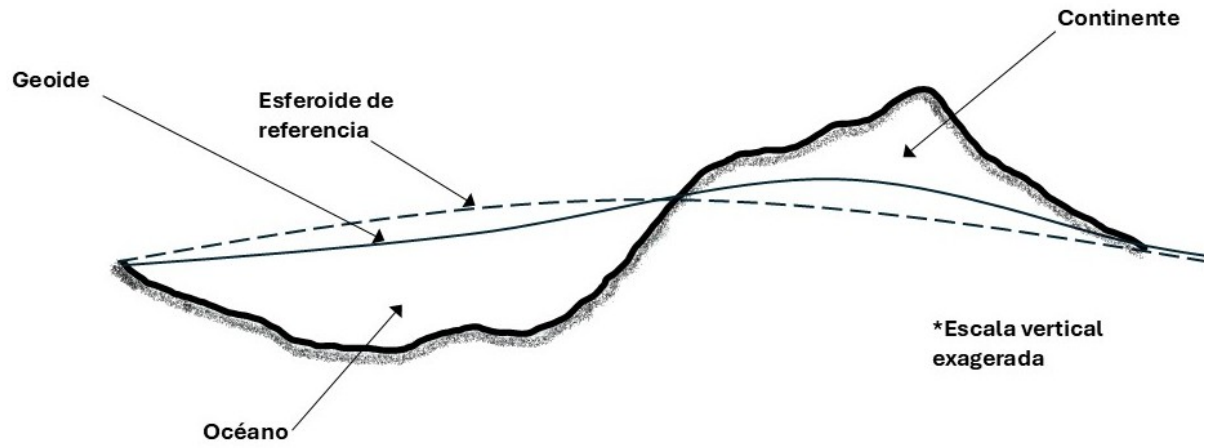


Figura 9. Comparación entre el esferoide y el geoide. Fuente: modificada de Telford et al. (1990).

Aunque la superficie de la Tierra no es uniforme, en su mayor parte las variaciones son constantes durante intervalos de tiempo muy largos. Esto significa que la influencia gravitatoria de estructuras geológicas en una ubicación determinada es prácticamente la misma durante un tiempo prolongado y se conoce como campo gravitatorio medio.

Sin embargo, existen otras variaciones de masa que ocurren en escalas de tiempo mucho más breves. Se deben principalmente a variaciones en el contenido de agua, ya que esta circula entre la atmósfera, los océanos, los continentes, los glaciares y las capas de hielo polares. Estas fluctuaciones de masa a menor plazo contribuyen a lo que se conoce como campo gravitatorio variable en el tiempo.

El campo gravitatorio medio es de gran valor para comprender la estructura de la Tierra sólida y ayudar a revelar aspectos de la circulación oceánica, mientras que las variaciones del campo gravitatorio variable en el tiempo se utilizan para otras aplicaciones, como el estudio de los cambios en el almacenamiento de agua sobre los continentes, estudios de hielo marino, el aumento del nivel del mar, las corrientes profundas del océano, la presión en el fondo marino y el flujo de calor del océano (NASA, 2023).

El geoide sirve como una superficie de referencia útil que define el plano horizontal en toda la corteza terrestre y la gravedad actúa de forma perpendicular a él proporcionando información crítica para modelos científicos aplicables a (NASA, 2023):

- Medir las corrientes oceánicas someras y profundas
- Medir la masa cambiante de las capas de hielo polares
- Medir los cambios en los recursos de agua en tierra

- Comprender el cambio del nivel del mar derivado de las variaciones de temperatura del océano y de la masa de agua

- Comprender el intercambio de masa entre la atmósfera y el océano

El *Gravity Recovery and Climate Experiment* (GRACE), lanzado por la NASA el 17 de marzo de 2002 y concluido el 27 de octubre de 2017, es diferente de la mayoría de los satélites de observación de la Tierra porque no lleva un conjunto de instrumentos científicos independientes a bordo y no realiza mediciones de la energía electromagnética que se refleja de vuelta desde la superficie de la Tierra. En su lugar, los dos satélites GRACE actúan en conjunto como el instrumento principal. Los cambios en la distancia entre los dos satélites se utilizan para hacer mediciones del campo gravitatorio.

Los dos satélites idénticos orbitan uno detrás del otro en el mismo plano orbital a una distancia aproximada de 220 km. Mientras la pareja rodea la Tierra, las áreas de gravedad ligeramente más fuerte afectarán primero al satélite líder, alejándolo del satélite que va detrás; luego, a medida que los satélites continúan a lo largo de su trayectoria orbital, el satélite que va detrás es atraído hacia el líder cuando pasa sobre la anomalía de gravedad (Figura 10). El cambio de distancia sería ciertamente imperceptible para nuestros ojos, pero el sistema de alcance por microondas extremadamente preciso de GRACE es capaz de detectar estos cambios diminutos en la distancia entre los satélites.

Un dispositivo de medición altamente preciso conocido como acelerómetro, ubicado en el centro de masa de cada satélite, se utilizará para medir las aceleraciones no gravitacionales (tales como las debidas a la resistencia atmosférica) para que solo se consideren las aceleraciones causadas por la gravedad. Los receptores del Sistema Global de Posicionamiento por Satélite (GPS) se usarán para determinar la posición exacta del satélite sobre la Tierra con una precisión de un centímetro o menos (NASA, 2023).

La misión *Gravity Recovery and Climate Experiment Follow-on* (GRACE-FO) es una colaboración entre la NASA y el Centro Alemán de Investigación en Geociencias. GRACE-FO, lanzada el 22 de mayo de 2018, es la sucesora de la misión GRACE original y continúa la labor de rastrear el movimiento del agua en la Tierra para monitorear los cambios en las reservas de agua subterráneas, la cantidad de agua en los grandes lagos y ríos, la humedad del suelo, las capas de hielo y los glaciares, así como el nivel del mar causado por la incorporación de agua al océano.

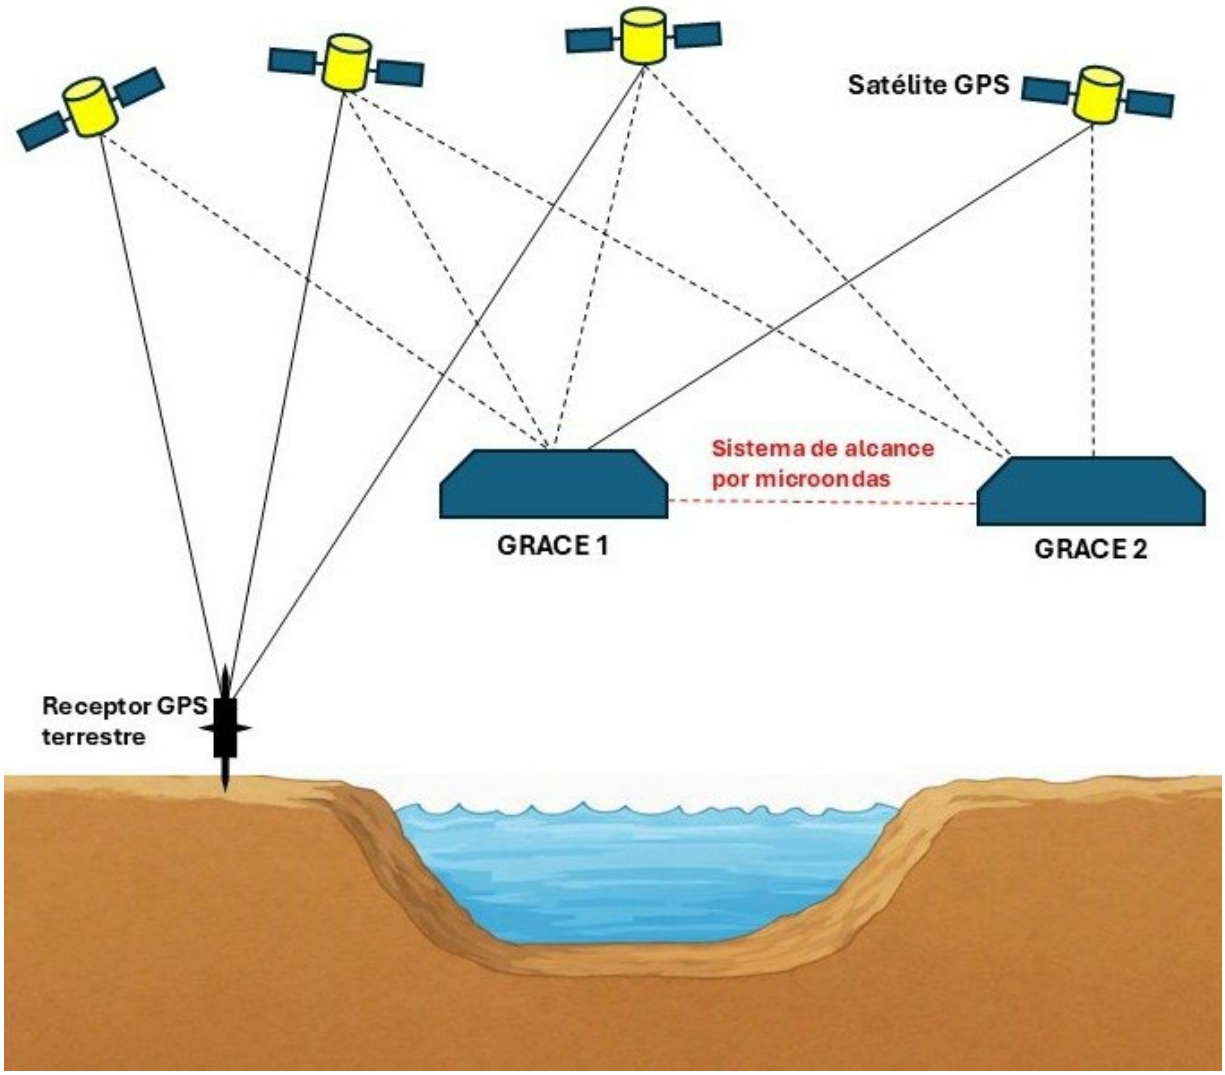


Figura 10. Concepto de la misión GRACE. Fuente: modificada de Baur et. al. (2007).

Tipos de productos globales

Si bien se suele tratar como datos de percepción remota a todo tipo de datos que tengan cobertura global o casi global y que hayan sido derivados de algún sensor montado en algún satélite, existen distintos tipos de datos dependiendo del origen o tipo de tratamiento que se le ha dado a la información. De manera general, estos datos se pueden agrupar como: percepción remota, productos globales, reanálisis.

Percepción remota

Se trata de datos derivados casi directamente de la información obtenida de sensores remotos montados en satélites. Esta información pudo haber sido corregida por distintos algoritmos, y aun así representa la misma variable que ha sido monitoreada por el satélite, por ejemplo, reflectancia de los sensores multiespectrales de la misión Landsat y Sentinel 2. También se agrupan en esta categoría resultados casi directos obtenidos con los datos satelitales, como

índices espectrales, datos de precipitación o de otra variable hidrológica obtenida a partir de aplicar alguna función matemática.

Reanálisis

Los datos de reanálisis están asociados principalmente a información climática generada a partir de la simulación numérica que utiliza técnicas de asimilación de datos medidos en tierra, datos de percepción remota, otras simulaciones, entre otras, con el fin de obtener la descripción más realista de las ocurrencias climáticas. Estos conjuntos de datos suelen ser difíciles de generar debido a los recursos computacionales requeridos. Ejemplo de este tipo de datos son los que se obtienen de ERA5 (fifth generation ECMWF atmospheric reanalysis of the global climate).

Productos globales

Aquí se agrupan a todos los demás tipos de datos. Se trata, por lo tanto, de datos hidrológicos, hidrogeológicos, entre otros, que pueden ser obtenidos mediante la simulación numérica, típicamente mediante la asimilación de datos derivados de percepción remota, por ejemplo, GLDAS (Global Land Data Assimilation System) y MERRA (The Modern-Era Retrospective Analysis for Research and Applications). También, productos globales incluye a los datos obtenidos mediante la interpolación de datos observados en tierra, o datos que han sido derivados de percepción remota pero que han pasado por procesos de corrección con datos en tierra, por ejemplo, los datos de precipitación de CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data).

Herramientas utilizadas

El manejo de grandes cantidades de datos constituye una disciplina multidisciplinaria que integra conocimientos de estadística, matemáticas, ingeniería informática e, incluso, inteligencia artificial. Su objetivo es extraer información útil, identificar patrones y generar conocimiento que apoye a la toma de decisiones. Esta área de estudio se conoce, de manera general, como ciencia de datos.

Cuando el procesamiento y análisis se enfocan en datos con una componente espacial o geográfica, como aquellos obtenidos mediante técnicas de percepción remota, sistemas de información geográfica (SIG) o sensores de posicionamiento, esta disciplina recibe el nombre de **ciencia de datos geoespaciales** o **análisis geoespacial**. Su propósito es transformar datos geográficos en información significativa que permita comprender fenómenos espaciales, monitorear cambios en el territorio y apoyar la planificación y gestión de recursos.

Para el desarrollo de las herramientas interactivas propuestas en este trabajo, se hizo uso de herramientas de programación, plataformas de cómputo en la nube y bases de datos derivados de percepción remota y productos globales, las cuales se describen a continuación.

Google Earth Engine

Los datos geoespaciales contienen información de un espacio georreferenciado en la Tierra en un tiempo determinado, por lo que requieren de una gran capacidad de almacenamiento, en consecuencia, el análisis geoespacial requiere de grandes capacidades de cómputo, lo que llevó a la empresa estadounidense *Google* a desarrollar una plataforma capaz de almacenar datos de distintas misiones satelitales además de permitir su procesamiento.

Google Earth Engine (GEE) combina un catálogo de más de 90 petabytes (90,000,000 GB) de datos satelitales y conjuntos de datos geoespaciales con capacidad de realizar análisis a escala planetaria (Gorelick, 2012). GEE actualmente está disponible para uso comercial, mientras que para investigación y uso académico es de uso libre (Gorelick *et al*., 2017). Cuenta con una estructura de tres elementos que permiten su funcionamiento: el catálogo de información, la capacidad computacional y las API (Solorsano *et al*., 2022).

Su extenso catálogo incluye más de cuarenta años de conjuntos de datos científicos e imágenes que se expande y actualiza diariamente con diferentes categorías de datos:

- Clima y meteorología: temperatura de la superficie, clima, atmosfera, meteorología.
- Imágenes multiespectrales: Landsat, Sentinel, MODIS, imágenes de alta resolución.
- Geofísica: Terreno, cubierta terrestre y tierra de cultivo.

Presenta dos modos de análisis:

- Modo interactivo: para exploración y visualización rápida en tiempo real de pequeñas cantidades de datos.
- Modo agrupado: para análisis intensivo a gran escala computacional en grandes cantidades de datos.

La Interfaz de Programación de Aplicaciones (API por sus siglas en inglés) permite la comunicación entre el servidor y el usuario facilitando la extracción de información de la nube de *Google*. GEE ofrece a los usuarios las API de los lenguajes de programación JavaScript y Python. La primera se presenta como un entorno de desarrollo dedicado, basado en la web para la creación rápida de prototipos, exploración y creación de aplicaciones, por otro lado, la API de Python ofrece una interfaz flexible que facilita los flujos de trabajo avanzados y análisis interactivo de conjuntos de datos con una codificación mínima haciendo uso del paquete *geemap*, el cual integra diferentes librerías de Python (Wu, 2023).

Python y entornos virtuales

Para el desarrollo de las herramientas se utilizó Python, un lenguaje de programación de código abierto, de alto nivel de lenguaje interpretado, de sintaxis fácil y legible, de tipado dinámico y multiplataforma (Python, 2015). Python ha ganado mucha popularidad en ciencias de la tierra por su facilidad de uso, por su ecosistema de desarrollo, gran variedad de librerías para análisis de datos, análisis geoespacial, visualización, etc.

Para el desarrollo de herramientas con Python se suelen utilizar ambientes virtuales. Un entorno virtual puede describirse como un entorno aislado de ejecución que permite a los usuarios de Python instalar y actualizar diferentes versiones de librerías sin interferir con el comportamiento de otras aplicaciones de Python en el mismo sistema (Python Software Foundation, 2025).

Entre las diversas herramientas para crear ambientes virtuales se encuentra uv, un gestor de paquetes y proyectos extremadamente rápido que proporciona características esenciales para el desarrollo en Python. uv permite: instalar y gestionar Python, ejecutar scripts independientes, crear y trabajar en proyectos y ejecutar e instalar herramientas de paquetes. Además, es útil en la gestión manual de entornos y paquetes ya que facilita los flujos de trabajo heredados o en casos en los que los comandos de alto nivel no proporcionan suficiente control (Astral, 2025).

Principales librerías

Jupyter Lab

Jupyter es un proyecto de código abierto sin ánimo de lucro, nacido del Proyecto IPython en 2014, que evolucionó para dar soporte a la ciencia de datos interactiva y a la computación científica en todos los lenguajes de programación (Project Jupyter, 2024). De este proyecto se desprende Jupyter Lab, el cual es una aplicación de creación y edición de notebooks altamente extensible y rica en funcionalidades.

Un notebook computacional es un documento que combina código informático, descripciones mediante texto, datos, visualizaciones enriquecidas como modelos 3D, diagramas, gráficos y figuras, y controles interactivos (Project Jupyter, 2024).

Pandas

Pandas es un proyecto de código abierto que tiene como objetivo la manipulación y análisis de datos tabulares, el cual ofrece dos tipos de estructuras: series y cuadro de datos, popularmente denominado *DataFrame* (McKinney, 2011). Esta librería ofrece una amplia gama de funciones, tales como:

- Un objeto DataFrame rápido y eficiente para la manipulación de datos con indexación integrada
- Herramientas para leer y escribir datos entre estructuras en memoria y diferentes formatos: archivos CSV y de texto, Microsoft Excel, bases de datos SQL y HDF5
- Alineación inteligente de datos y manejo integrado de datos faltantes
- Remodelación y pivoteo flexible de conjuntos de datos
- Segmentación inteligente basada en etiquetas, indexación sofisticada y subconjuntos de grandes conjuntos de datos
- Fusión y unión de conjuntos de datos de alto rendimiento
- Funciones de series temporales: generación de rangos de fechas y conversión de frecuencias, estadísticas de ventanas móviles, desplazamiento y retraso de fechas.

Geemap

Geemap es una librería para el lenguaje de programación Python para el análisis interactivo y visualización de datos geoespaciales provenientes de GEE (Wu, 2023). Algunas de sus principales características con base en GEE se describen como:

- Convertir proyectos de GEE JavaScript a scripts de Python y notebooks de Jupyter.
- Visualizar capas de datos en mapas interactivos.
- Visualizar vectores y rásters sin necesidad de código.
- Recuperar datos interactivamente con el uso de herramientas de inspección.
- Convertir datos entre los formatos GeoJSON a *FeatureCollection* de GEE.
- Exportar datos en formatos shp, csv, json, kml, kmz, entre otros.
- Exportar estructuras de *ImageCollection* y *Image* de GEE como GeoTIFF.
- Extraer pixeles de una *Image* de GEE a un arreglo numpy 3D.
- Calcular estadísticas zonales por grupo.
- Buscar lugares y conjuntos de datos del catálogo de GEE.
- Usar el inspector de series de tiempo para visualizar el cambio del paisaje a través del tiempo.
- Agregar rásters propios a los mapas.
- Realizar la clasificación de imágenes y evaluar la precisión.
- Extraer interactivamente valores de los pixeles y exportarlos como shp y csv.

Panel

Es una librería de Python de código abierto diseñada para agilizar el desarrollo de dashboards o interfaces para el análisis de datos. Su conjunto de características incluye APIs reactivas de alto nivel y APIs basadas en callbacks de bajo nivel, permitiendo un rápido desarrollo de aplicaciones exploratorias y facilitando la creación de aplicaciones complejas con amplia interactividad (Holoviz, 2025). Panel facilita:

- Desarrollar aplicaciones en el editor de su preferencia o entorno de notebooks.
- Combinar las herramientas y librerías de visualizaciones usualmente utilizadas.
- Iterar rápidamente para desarrollar herramientas complejas.
- Crear aplicaciones de datos que puedan ejecutarse íntegramente en el navegador.

Desarrollo de las herramientas computacionales

Repositorio

Las herramientas desarrolladas están disponibles de forma gratuita en un repositorio de GitHub, la cual es una plataforma para almacenar, compartir y trabajar junto con otros usuarios para desarrollar código (GitHub, Inc., 2025).

Los códigos y las instrucciones de instalación se encuentran disponibles en:

https://github.com/IsabelCelso/Monitoreo_GEE.git

Análisis espacio-temporal de variables hidrológicas / hidrogeológicas en acuíferos

Las características cuantitativas que definen el estado del recurso hídrico en cualquier momento de su ciclo se denominan variables hidrológicas y/o hidrogeológicas. La mayoría de estas variables corresponden a medidas puntuales, requiriendo grandes conjuntos de instrumentos para cubrir áreas extensas, mientras que, en otros casos, las variables son costosas o difíciles de medir de manera directa, por lo que no siempre se cuenta con la estructura y recursos necesarios para realizar un seguimiento de los procesos hidrológicos e hidrogeológicos. Tomando lo anterior como referencia, se desarrolló una herramienta de monitoreo a escala de acuíferos de México (Figura 11) implementando GEE a través de la API de Python para la descarga y visualización de información de las variables hidrológicas y/o hidrogeológicas. Las fuentes de datos derivados de percepción remota y productos globales utilizados se muestran en la Tabla 2. Por su parte, la capa vectorial de acuíferos fue obtenida del Sistema Nacional de Información del Agua (SINA) de la Comisión Nacional del Agua (CONAGUA).

La capa vectorial de acuíferos en formato shapefile de ESRI (.shp) es leída con la librería de Google Earth Engine (API ee) (Figura 12). Esta capa es usada para realizar un corte espacial de las bases de datos a partir del área de un acuífero seleccionado.

La Figura 13 muestra la declaración de todas las bases de datos y variables hidrológicas e hidrogeológicas implementadas en el código a través de un diccionario.

Una vez que se ejecuta todo el código, se mostrarán las opciones de selección de acuífero, bases de datos, fechas y escala temporal (Figura 14). En la zona de las herramientas interactivas, se selecciona la clave del acuífero (Figura 14.1) y la variable de la que se descargara la serie de tiempo (Figura 14.2), además, se elige la temporalidad de la serie (Figura 14.3).

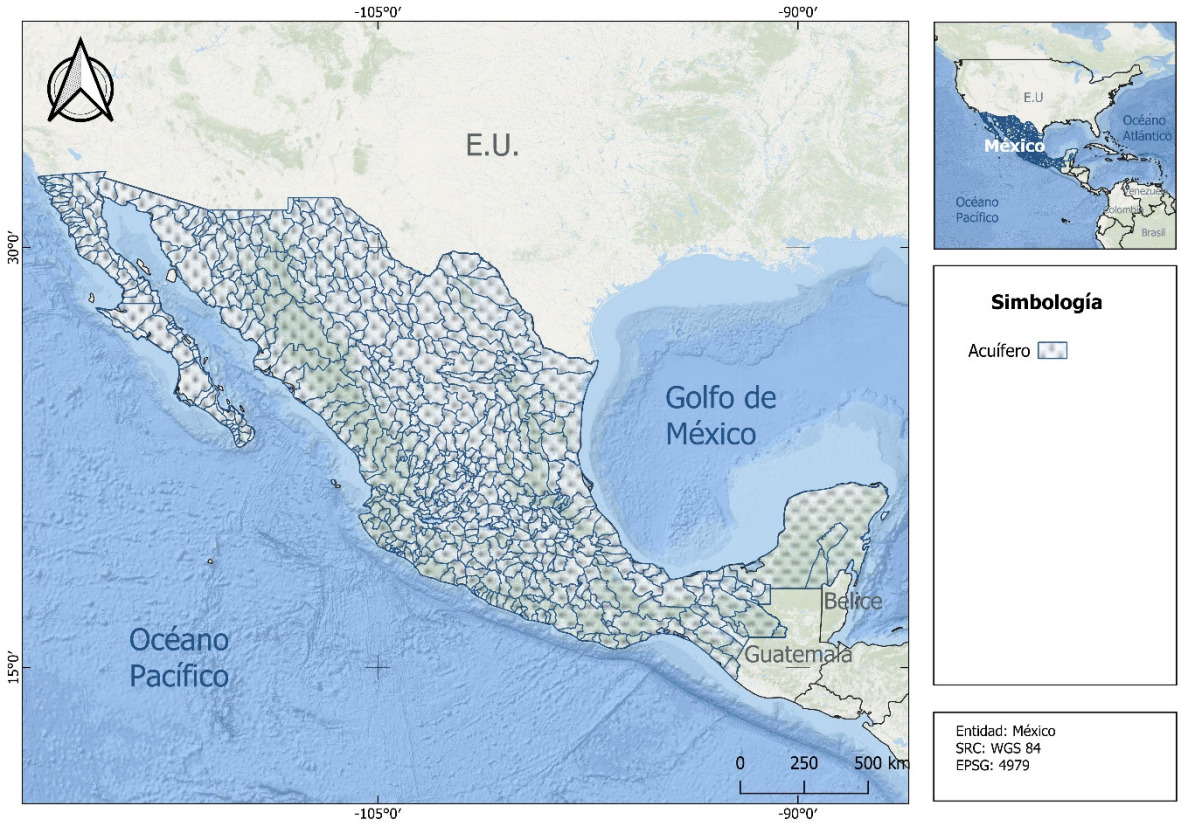


Figura 11. Mapa de los 653 acuíferos administrativos en México.

```
1  # @title Importar librerias
2  # Importación de módulos
3  import json
4  import datetime
5  from time import sleep
6  import numpy as np
7  import pandas as pd
8  import geemap.foliumap as geemap
9  import eemont
10 import ee
11
12 from pprint import pprint
13
14 import plotly.offline as po
15 import plotly.express as pe
16 import plotly.graph_objects as go
17
18 import panel as pn
19 from io import StringIO
20 from IPython.display import display
21
22 pn.extension('plotly')
23 pn.extension(design = 'material')
24
25 import warnings
26 warnings.filterwarnings("ignore")
```

Figura 12. Importación de librerías y módulos necesarios para la ejecución del programa.

```python
# Diccionario de colecciones
colecciones = {
    "3B43V7 - Precipitación": ('TRMM/3B43V7', 'precipitation', 'mm', 720, "mean", "Mensual"),
    "CHIRPS - Precipitación": ('UCSB-CHG/CHIRPS/DAILY', 'precipitation', 'mm', 1, "sum", "Diario"),
    "GLDAS - AvgSurfT": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'AvgSurfT_tavg', 'K', 1, "mean", "Diario"),
    "GLDAS - CanopInt": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'CanopInt_tavg', 'mm', 1, "mean", "Diario"),
    "GLDAS - ECanop": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'ECanop_tavg', 'mm', 86400, "mean", "Diario"),
    "GLDAS - ESoil": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'ESoil_tavg', 'mm', 86400, "mean", "Diario"),
    "GLDAS - EvapSnow": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'EvapSnow_tavg', 'mm', 86400, "mean", "Diario"),
    "GLDAS - Evap": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'Evap_tavg', 'mm', 86400, "mean", "Diario"),
    "GLDAS - TVeg": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'TVeg_tavg', 'mm', 86400, "mean", "Diario"),
    "GLDAS - GWS": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'GWS_tavg', 'mm', 1, "mean", "Diario"),
    "GLDAS - TWS": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'TWS_tavg', 'mm', 1, "mean", "Diario"),
    "GLDAS - SoilMoist_P": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'SoilMoist_P_tavg', 'mm', 1, "mean", "Diario"),
    "GLDAS - SoilMoist_RZ": ('NASA/GLDAS/V022/CLSM/G025/DA1D', 'SoilMoist_RZ_tavg', 'mm', 1, "mean", "Diario"),
    "DAYMET_V4 - tmax": ('NASA/ORNL/DAYMET_V4', 'tmax', '°C', 1, "mean", "Diario"),
    "DAYMET_V4 - tmin": ('NASA/ORNL/DAYMET_V4', 'tmin', '°C', 1, "mean", "Diario"),
    "ERA5 - TMdA": ('ECMWF/ERA5/DAILY', 'mean_2m_air_temperature', 'K', 1, "mean", "Diario"),
    "ERA5 - TMnA": ('ECMWF/ERA5/DAILY', 'minimum_2m_air_temperature', 'K', 1, "mean", "Diario"),
    "ERA5 - TMxA": ('ECMWF/ERA5/DAILY', 'maximum_2m_air_temperature', 'K', 1, "mean", "Diario"),
    "ERA5 - TP": ('ECMWF/ERA5/DAILY', 'total_precipitation', 'mm', 1000, "sum", "Diario"),
    "ERA5 - SP": ('ECMWF/ERA5/DAILY', 'surface_pressure', 'Pa', 1, "mean", "Diario"),
    "IMERG_MONTHLY_V06 - Precipitación": ('NASA/GPM_L3/IMERG_MONTHLY_V06', 'precipitation', 'mm', 720, "mean", "Mensual"),
    "MOD16A2-ET": ('MODIS/061/MOD16A2', 'ET', 'mm', 0.1, "mean", "Semanal"),
    "MOD13A2 - EVI": ('MODIS/061/MOD13A2', 'EVI', ' ', 0.0001, "mean", "Mensual"),
    "MCD15A3H - Lai": ('MODIS/061/MCD15A3H', 'Lai', ' ', 0.1, "mean", "Semanal"),
    "MOD13A2 - NDVI": ('MODIS/061/MOD13A2', 'NDVI', ' ', 0.0001, "mean", "Mensual"),
    "MOD16A2-PET": ('MODIS/061/MOD16A2', 'PET', 'mm', 0.1, "mean", "Semanal"),
    "TERRACLIMATE - aet": ('IDAHO_EPSCOR/TERRACLIMATE', 'aet', 'mm', 0.1, "sum", "Mensual"),
    "TERRACLIMATE - soil": ('IDAHO_EPSCOR/TERRACLIMATE', 'soil', 'mm', 0.1, "mean", "Mensual"),
    "TERRACLIMATE - tmmn": ('IDAHO_EPSCOR/TERRACLIMATE', 'tmmn', '°C', 0.1, "mean", "Mensual"),
    "TERRACLIMATE - tmmx": ('IDAHO_EPSCOR/TERRACLIMATE', 'tmmx', '°C', 0.1, "mean", "Mensual"),
    "PERSIANN-CDR -  Precipitación": ('NOAA/PERSIANN-CDR', 'precipitation', 'mm', 1, "sum", "Diario")
}
```

Figura 13. Diccionario de colecciones. Incluye: variable a consultar, unidad de medida, factor de conversión y escala temporal.

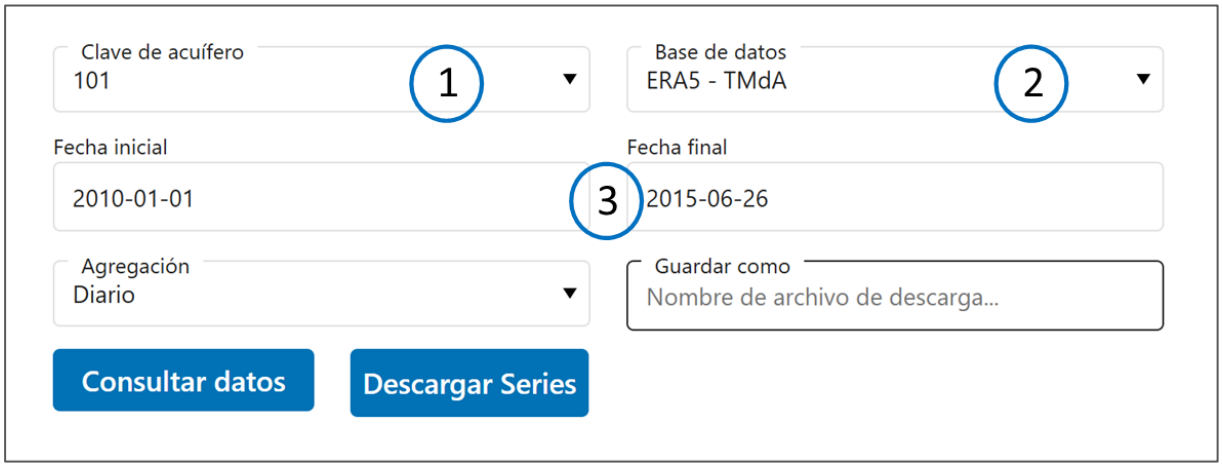


Figura 14. Herramientas interactivas para la consulta y descarga de series de tiempo. 1. Seleccionar acuífero. 2. Variable a descargar. 3. Rango de tiempo.

El código entonces utiliza la información seleccionada en la función *get_data()* (Figura 15) la cual procesa las imágenes como un conjunto de datos a escala del acuífero seleccionado, y se promedia espacialmente para convertir a una serie de tiempo con la función *collection_timeserie()* (Figura 16). Esta función hace uso de la librería pandas (Figura 12) para integrar los a datos a un DataFrame.

Tabla 2. Variables hidrológicas e hidrogeológicas.

Variable	Colección	Descripción
3B43V7 - Precipitación	TRMM/3B43V7	Precipitación estimada por microondas/IR
CHIRPS - Precipitación	UCSB-CHG/CHIRPS/DAILY	Precipitación
GLDAS - AvgSurfT	NASA/GLDAS/V022/CLSM/G025/DA1D	Temperatura media de la superficie
GLDAS - CanopInt	NASA/GLDAS/V022/CLSM/G025/DA1D	Agua superficial de la cubierta vegetal
GLDAS - ECanop	NASA/GLDAS/V022/CLSM/G025/DA1D	Evaporación de agua de las cimas de GLDAS
GLDAS - ESoil	NASA/GLDAS/V022/CLSM/G025/DA1D	Evaporación de agua del suelo desnudo
GLDAS - EvapSnow	NASA/GLDAS/V022/CLSM/G025/DA1D	Evaporación de la nieve de GLDAS
GLDAS - Evap	NASA/GLDAS/V022/CLSM/G025/DA1D	Evapotranspiración
GLDAS - TVeg	NASA/GLDAS/V022/CLSM/G025/DA1D	Transpiración
GLDAS - GWS	NASA/GLDAS/V022/CLSM/G025/DA1D	Almacenamiento de agua subterránea
GLDAS - TWS	NASA/GLDAS/V022/CLSM/G025/DA1D	Almacenamiento de agua terrestre
GLDAS - SoilMoist_P	NASA/GLDAS/V022/CLSM/G025/DA1D	Perfil de humedad del suelo
GLDAS - SoilMoist_RZ	NASA/GLDAS/V022/CLSM/G025/DA1D	Humedad del suelo de zona con raíces
DAYMET_V4 - tmax	NASA/ORNL/DAYMET_V4	Temperatura máxima del aire a 2m
DAYMET_V4 - tmin	NASA/ORNL/DAYMET_V4	Temperatura mínima del aire a 2m
ERA5 - TMdA	ECMWF/ERA5/DAILY	Temperatura diaria media del aire a 2m de altura
ERA5 - TMnA	ECMWF/ERA5/DAILY	Temperatura diaria mínima del aire a 2m de altura
ERA5 - TMxA	ECMWF/ERA5/DAILY	Temperatura diaria máxima del aire a 2m de altura
ERA5 - TP	ECMWF/ERA5/DAILY	Precipitación
ERA5 - SP	ECMWF/ERA5/DAILY	Presión superficial
IMERG_MONTHLY_V06 - Precipitación	NASA/GPM_L3/IMERG_MONTHLY_V06	Estimación de la precipitación por satélite y manómetro
MOD16A2-ET	MODIS/061/MOD16A2	Evapotranspiración
MOD13A2 - EVI	MODIS/061/MOD13A2	Índice de vegetación mejorado
MCD15A3H - Lai	MODIS/061/MCD15A3H	Superficie de una hoja verde
MOD13A2 - NDVI	MODIS/061/MOD13A2	Índice de vegetación normalizada
MOD16A2-PET	MODIS/061/MOD16A2	Evapotranspiración potencial
TERRACLIMATE - aet	IDAHO_EPSCOR/TERRACLIMATE	Evapotranspiración
TERRACLIMATE - soil	IDAHO_EPSCOR/TERRACLIMATE	Humedad del suelo
TERRACLIMATE - tmmn	IDAHO_EPSCOR/TERRACLIMATE	Temperatura mínima
TERRACLIMATE - tmmx	IDAHO_EPSCOR/TERRACLIMATE	Temperatura máxima
PERSIANN-CDR - Precipitación	NOAA/PERSIANN-CDR	Precipitación diaria estimada

```python
# Descarga de serie definida por acuífero y base de datos
def get_data(Clave_acuifero, Base_de_datos, fecha_in, fecha_fin):
    attributes = colecciones[Base_de_datos]
    geom = capa.filter(ee.Filter.eq(columna, Clave_acuifero))

    yearst = int(fecha_in[0:4])
    yearnd = int(fecha_fin[0:4])
    monthst = (fecha_in[5:7])
    monthnd = (fecha_fin[5:7])
    dayst = (fecha_in[8:10])
    daynd = (fecha_fin[8:10])

    escala    = 5000  # en m
    presicion = 5     # numero de decimales a guardar
    dy        = 5     # numero de años a descargar en una peticion
    year1 = np.arange(yearst, yearnd+1, dy)
    year2 = year1 + dy
    if year2[-1] > yearnd: year2[-1] = yearnd
    years = list(zip(year1, year2))

    serie = []
    for y1, y2 in years:
        start = f"{y1}-{monthst}-{dayst}"
        if y2 < yearnd:
            date2 = pd.to_datetime(f"{y2}-{monthst}-{dayst}") - pd.Timedelta("1d")
            end = date2.strftime("%Y-%m-%d")
        else:
            end = f"{y2}-{monthnd}-{daynd}"
        dataset = (ee.ImageCollection(attributes[0])
                   .filterBounds(geom)
                   .filterDate(start, end))
        try:
            ts = collection_timeserie(dataset, geom, attributes[1], escala) * attributes[3]
        except:
            sleep(30)
            ts = collection_timeserie(dataset, geom, attributes[1], escala) * attributes[3]
        sleep(1)
        serie.append(ts)

    pd_serie = pd.concat(serie)

    return pd_serie, attributes
```

Figura 15. Código para la función get_data().

```python
# Obtención de las series por región para la colección de imágenes y geometría dadas
def collection_timeserie(collection, geom, band, scale = 30, reducer = "mean"):
    if reducer == "mean":
        reducer = ee.Reducer.mean()
    elif reducer == "sum":
        reducer = ee.Reducer.sum()
    elif reducer == "count":
        reducer = ee.Reducer.count()
    elif reducer == "covariance":
        reducer = ee.Reducer.covariance()
    elif reducer == "std":
        reducer = ee.Reducer.stdDev()
    elif reducer == "min":
        reducer = ee.Reducer.min(1)
    elif reducer == "max":
        reducer = ee.Reducer.max(1)

    ts = collection.getTimeSeriesByRegion(
        reducer = [reducer],
        geometry = geom,
        bands = [band],
        scale = scale,
        maxPixels= 1e10
    )
    serie = gee_ts_to_serie(ts, band).loc[:, band]
    return serie
```

Figura 16. Código para la función collection_timeserie().

Las series procesadas se utilizan para generar la gráfica que muestra el comportamiento de la variable en el periodo de tiempo seleccionado (Figura 17.2), además de que se pueden exportar a un archivo delimitado por comas (*csv)* (Figura 17.1).

Análisis de la variación temporal del área inundada en embalses de presas con imágenes Landsat

Las presas son estructuras hidráulicas de grandes dimensiones que permiten almacenar o retener agua para aprovecharla en actividades como el riego, el consumo humano, la generación de energía eléctrica, entre otras (Centro Nacional de Prevención de Desastres, 2025).

El Sistema Nacional de Información de Agua (SINA) de la Comisión Nacional del Agua (CONAGUA) proporciona los datos del monitoreo de las principales presas de México, con lo cual se puede conocer la variación temporal del almacenamiento de la presa, la elevación del agua, y el área inundada, sin embargo, estos datos suelen ser derivados de una curva que relaciona la elevación del almacenamiento del embalse de la presa con el volumen almacenado o con el área inundada, por lo que los datos satélites podrían brindar una mejora en el monitoreo de las condiciones de las presas.

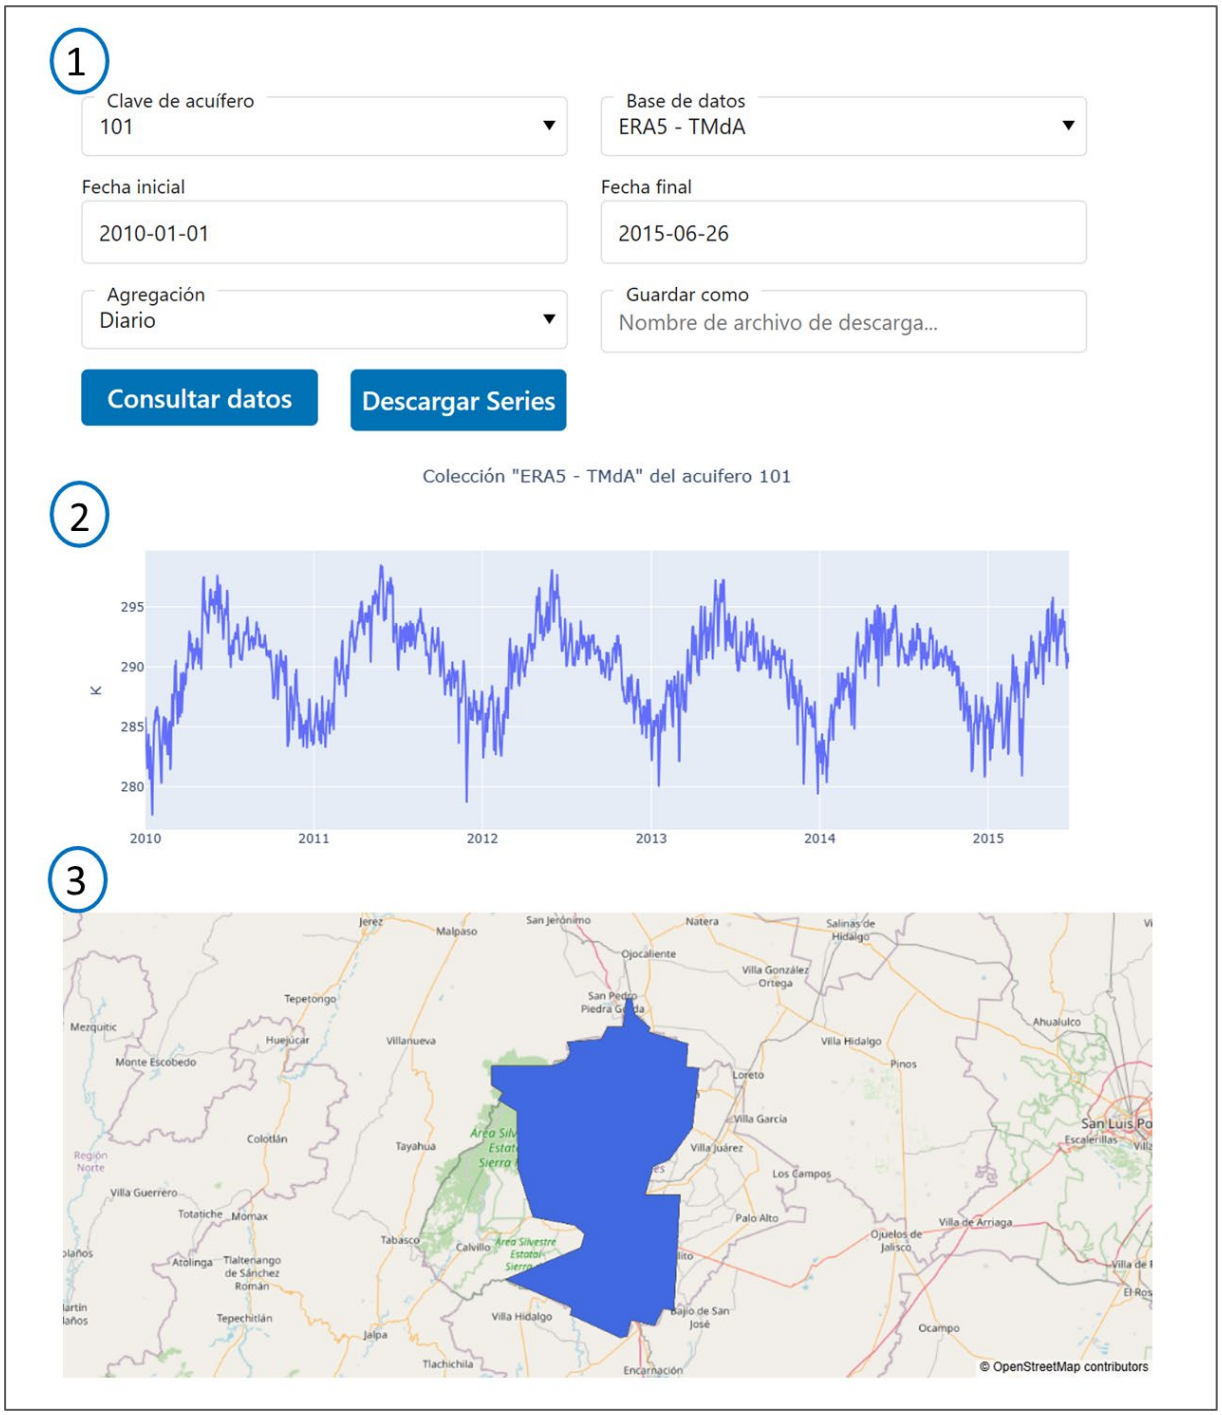


Figura 17. Salida a pantalla de la herramienta de monitoreo.

La segunda herramienta de monitoreo desarrollada permite aproximar el área inundada por las presas implementando las imágenes del programa Landsat 5 y Landsat 8 del Servicio Geológico de los Estados Unidos (USGS), consultadas mediante la API de GEE desde Python (Figura 18). Las presas monitoreadas corresponden a las ubicadas en el centro y norte del país (Figura 19), y la lista completa se muestra dentro del archivo /Notebooks Monitoreo con GEE/data/presas_info.csv del repositorio compartido.

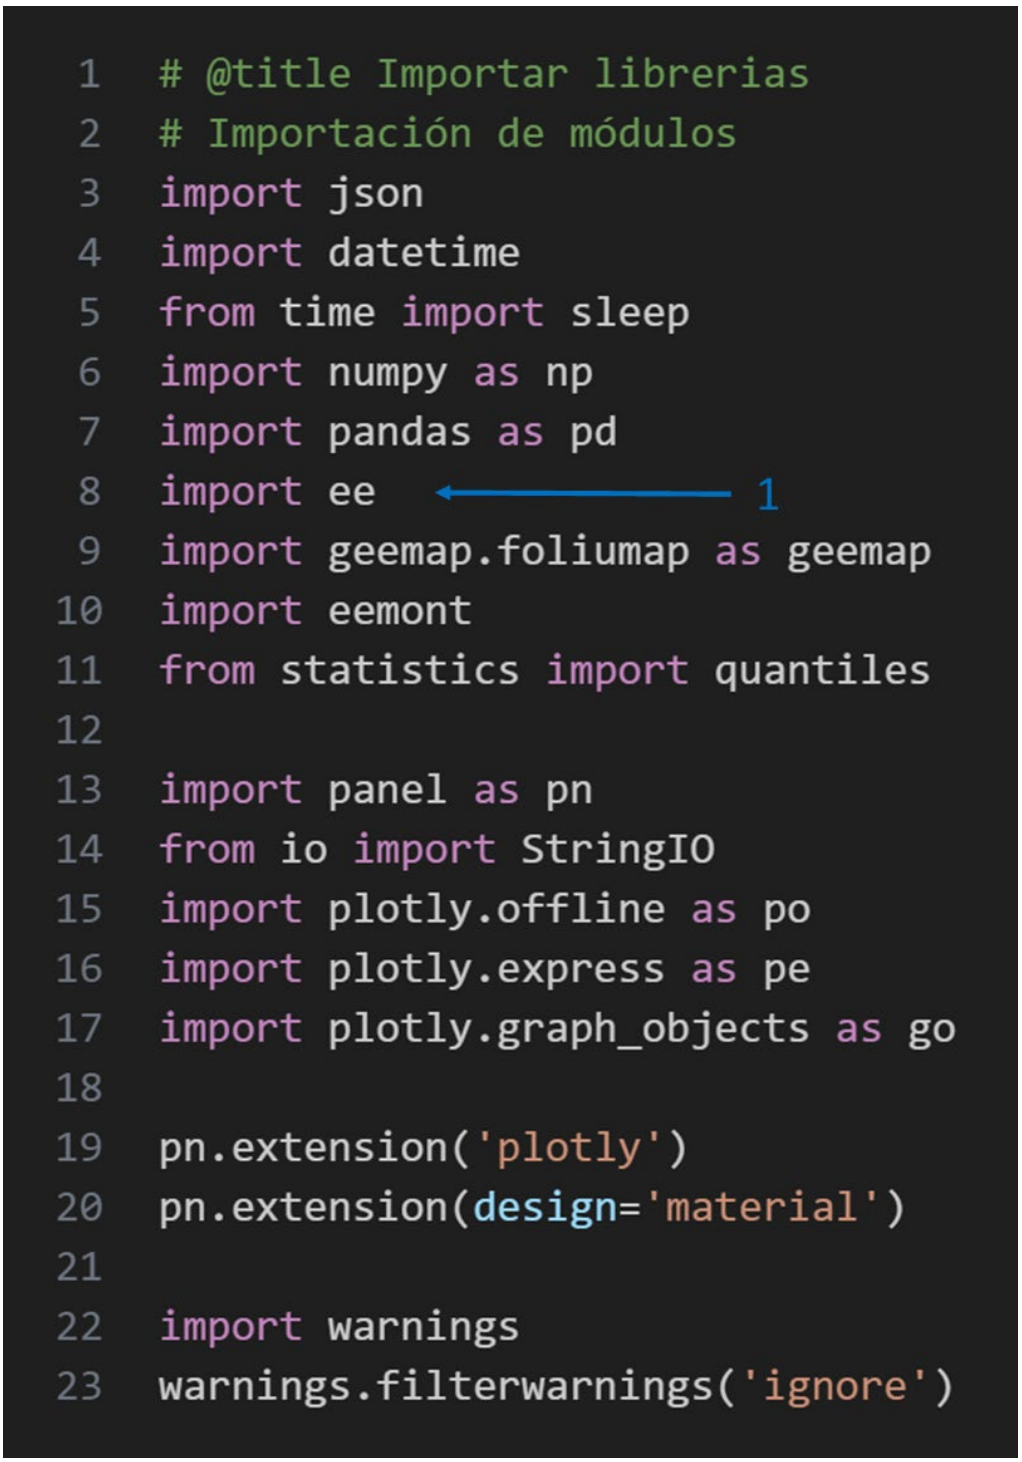


Figura 18. Importación de librerías y módulos necesarios para la ejecución del programa.

La ubicación de las presas fue obtenida del portal SINA de la CONAGUA, y para obtener el área inundada en cada presa, primero se generó una capa que contiene polígonos que limitan el área de análisis para evitar analizar zonas inundadas aledañas a las presas. Estos archivos están contenidos en el archivo /*Notebooks Monitoreo con GEE/data/presas_info.csv* y /*Notebooks Monitoreo con GEE/data/Presas.shp*. Dentro de la herramienta de monitoreo, la información de las presas es almacenada en un diccionario para realizar la selección de la presa de interés (Figura 20).

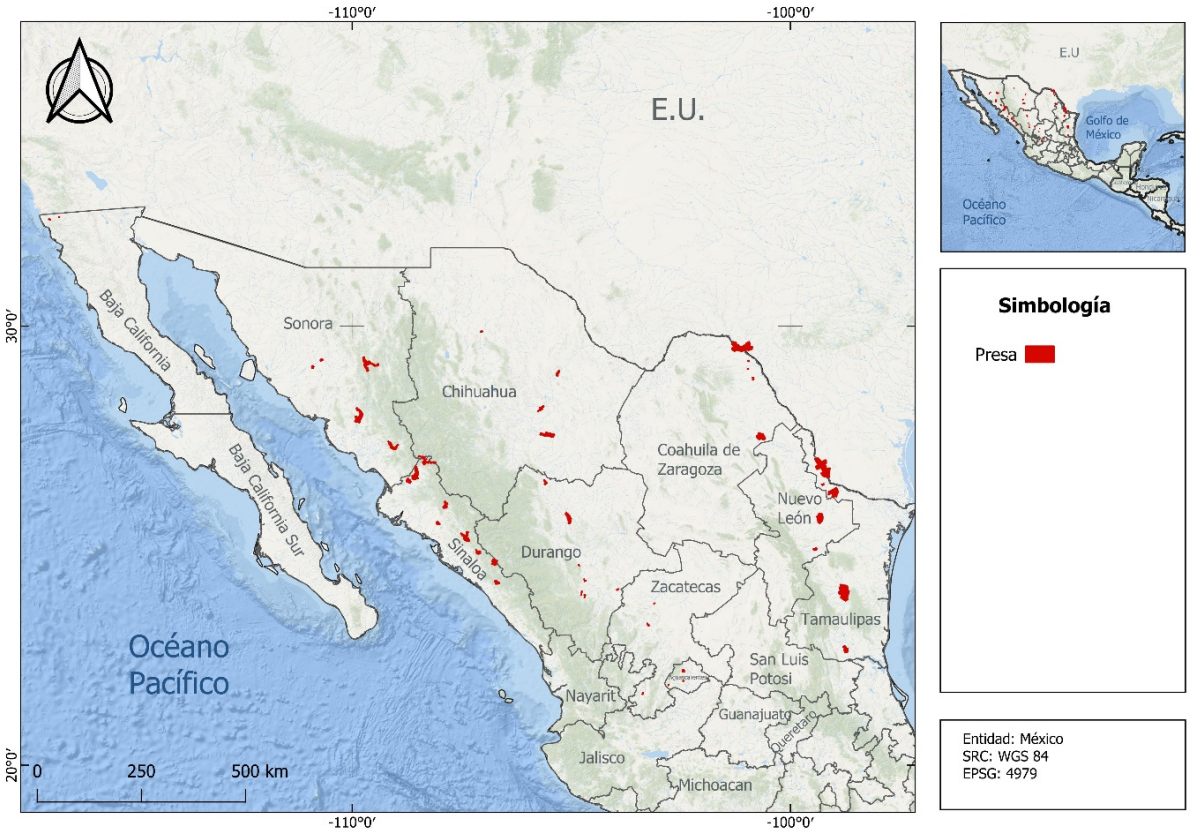


Figura 19. Mapa de las presas monitoreadas.

```python
# @title Generar información de las presas

# Construcción de mapa con datos geograficos y de identidad
layer_file = r"./data/Presas.shp"
info_file = r"./data/presas_info.csv"
capa = geemap.shp_to_ee(layer_file)
info = pd.read_csv(info_file)

# Extracción de atributos de la capa
capa_atributos = capa.getInfo()
columna = "Clave"
campos = [item["properties"][columna] for item in capa_atributos["features"]]
coord = [item["geometry"]["coordinates"] for item in capa_atributos["features"]]
areas = pd.Series(
    [item["properties"]["Area"] for item in capa_atributos["features"]],
    index = campos,
)
data = {"id": campos, "coor": coord}
ubi = pd.DataFrame(data)

# Diccionario de claves
clave = {f"{info.iloc[i, 0]} - {info.iloc[i, 3]}": info.iloc[i, 1] for i in range(len(info))}
```

Figura 20. Importación de los archivos necesarios para la construcción del mapa.

Una vez ejecutada la herramienta de monitoreo, en la zona de opciones se selecciona la clave y nombre de la presa a consultar (Figura 21.1). La clave de la presa es utilizada por la función *get_data()* (Figura 22) para definir la geometría de análisis para las imágenes satelitales. La geometría es utilizada en la función *compute_flooded_area()* (Figura 23), con la que se estima el área inundada por la presa en hectáreas.

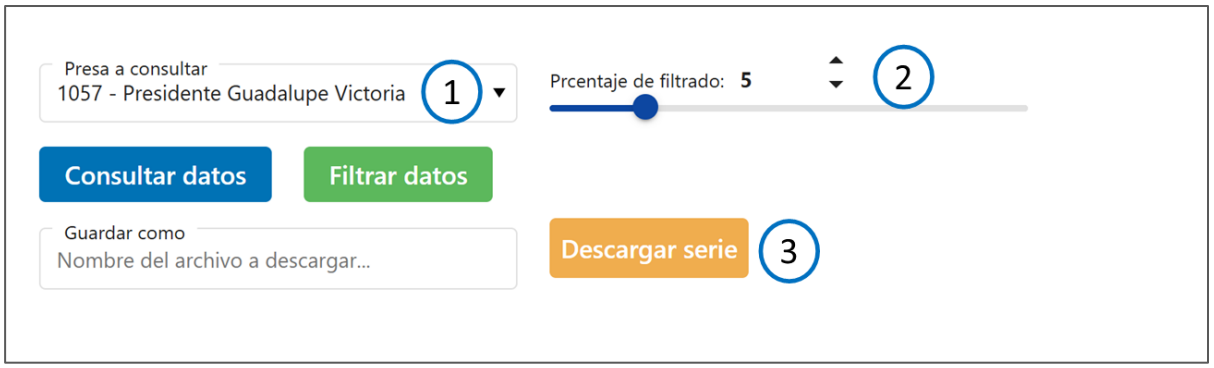


Figura 21. Herramientas interactivas para la consulta y descarga de series de tiempo. 1. Presa a consultar. 2. Filtrado de datos. 3. Descargar serie.

La función *compute_flooded_area()* filtra las imágenes satelitales de Landsat con menos del cinco por ciento de nubosidad para el periodo de tiempo de 1984 al presente. Posteriormente se calcula la diferencia normalizada con las bandas asociadas a la longitud de onda verde e infra roja cercana (NIR), necesarias para el cálculo del Índice de Agua de Diferencia Normalizada (NDWI). A partir del NDWI se identifican aquellos pixeles con valores mayores a cero, correspondientes a zonas con agua.

Finalmente, la función *collection_timeserie()* determina el número de pixeles con NDWI>0 y los multiplica por el tamaño del píxel (900 m^2) para determinar la variación temporal del área inundada en hectáreas. La serie de tiempo a su vez se introduce en la función *gee_ts_to_serie()* (Figura 24), para convertirla en un DataFrame de pandas para su visualización (Figura 25.2) y descarga en formato delimitado por comas (.csv) (Figura 21.3). Por otro lado, con la opción de filtrado de datos (Figura 21.2) es posible eliminar valores atípicos ubicados fuera del rango de aceptación, utilizando el método intercuartílico con el algoritmo siguiente: sea n el tamaño de muestra, en donde los valores de la muestra se ordenan del más pequeño al más grande. Para encontrar el primer cuantil (Q_1), se calcula el valor $0.25\ (n+1)$, si este es entero, entonces el valor de la muestra en esa posición es el primer cuantil. El tercer cuartil (Q_3) se calcula de la misma manera, excepto que se usa el valor $0.75\ (n+1)$. Se calcula el rango intercuartílico ($IQR = Q_3 - Q_1$). Se establecen los límites de aceptación por convención:

- Límite inferior: $Q_1 - 1.5 \cdot IQR$

- Limite superior: $Q_3 + 1.5 \cdot IQR$

Los valores que se encuentren fuera de los límites establecidos serán eliminados generando un conjunto de datos depurado (Figura 26.2) (Navidi, 2006).

```python
# Generador de datos y obtención de serie de tiempo
def get_data(clave_presa):
    nombre_clave = clave[clave_presa]
    geometry = capa.filter(ee.Filter.eq(columna, nombre_clave)).first().geometry()

    serie = []
    try:
        area = compute_flooded_area(geometry, areas[nombre_clave])
    except:
        sleep(30)
        area = compute_flooded_area(geometry, areas[nombre_clave])
    sleep(1)
    serie.append(area)

    df_serie = pd.concat(serie)
    return df_serie
```

Figura 22. Código para la función get_data().

```python
# Cálculo de de área inundada
def compute_flooded_area(geometry, geom_area):
    cloud_percent = 5
    landsat5 = (ee.ImageCollection("LANDSAT/LT05/C02/T1_L2")
                .filterDate("1984-03-16", "2012-05-05")
                .filterBounds(geometry)
                .filter(ee.Filter.lt("CLOUD_COVER", cloud_percent)));
    ndwi_l5 = collection_normalized_difference(landsat5, "SR_B2", "SR_B4", name = "ndwi")
    ndwi_l5_cliped = clip_collection(ndwi_l5, geometry)
    ndwi_l5_filtered = filter_collection(ndwi_l5_cliped, gt = 0)
    area_l5 = collection_timeserie(ndwi_l5_filtered, geometry, "ndwi", scale = 30, reducer = "count")
    total_area = collection_timeserie(ndwi_l5_cliped, geometry, "ndwi", scale = 30, reducer = "count")
    mask = ((total_area * 30 * 30) / geom_area) > 0.9
    area_l5 = area_l5.loc[mask]

    now = datetime.datetime.now().strftime("%Y-%m-%d")
    landsat8 = (ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
              .filterDate("2013-03-18", now)
              .filterBounds(geometry)
              .filter(ee.Filter.lt("CLOUD_COVER", cloud_percent)));
    ndwi_l8 = collection_normalized_difference(landsat8, "SR_B3", "SR_B5", name = "ndwi")
    ndwi_l8_cliped = clip_collection(ndwi_l8, geometry)
    ndwi_l8_filtered = filter_collection(ndwi_l8_cliped, gt = 0)
    area_l8 = collection_timeserie(ndwi_l8_filtered, geometry, "ndwi", scale = 30, reducer = "count")
    total_area = collection_timeserie(ndwi_l8_cliped, geometry, "ndwi", scale = 30, reducer = "count")
    mask = ((total_area * 30 * 30) / geom_area) > 0.9
    area_l8 = area_l8.loc[mask]

    area = pd.concat([area_l5, area_l8])
    return area.rename("area")*(30*30/10000)
```

Figura 23. Código para la función compute_flooded_area.

```python
# Conversión de las series temporales por región
# a series de tiempo en la librería pandas
def gee_ts_to_serie(ts, var):
    info = ts.getInfo()
    data = []
    for feat in info["features"]:
        d = feat["properties"]
        data.append([d["date"], d[var]])
    df = pd.DataFrame(data, columns = ["date", var])
    df.set_index("date", inplace = True)
    df.index = pd.to_datetime(df.index)
    df[df == -9999] = np.nan
    df = df.dropna()
    dates = pd.to_datetime([f"{x.year}-{x.month}-{x.day}" for x in df.index])
    df.index = dates
    df.sort_index(inplace=True)
    return df
```

Figura 24. Código para la función gee_ts_to_serie().

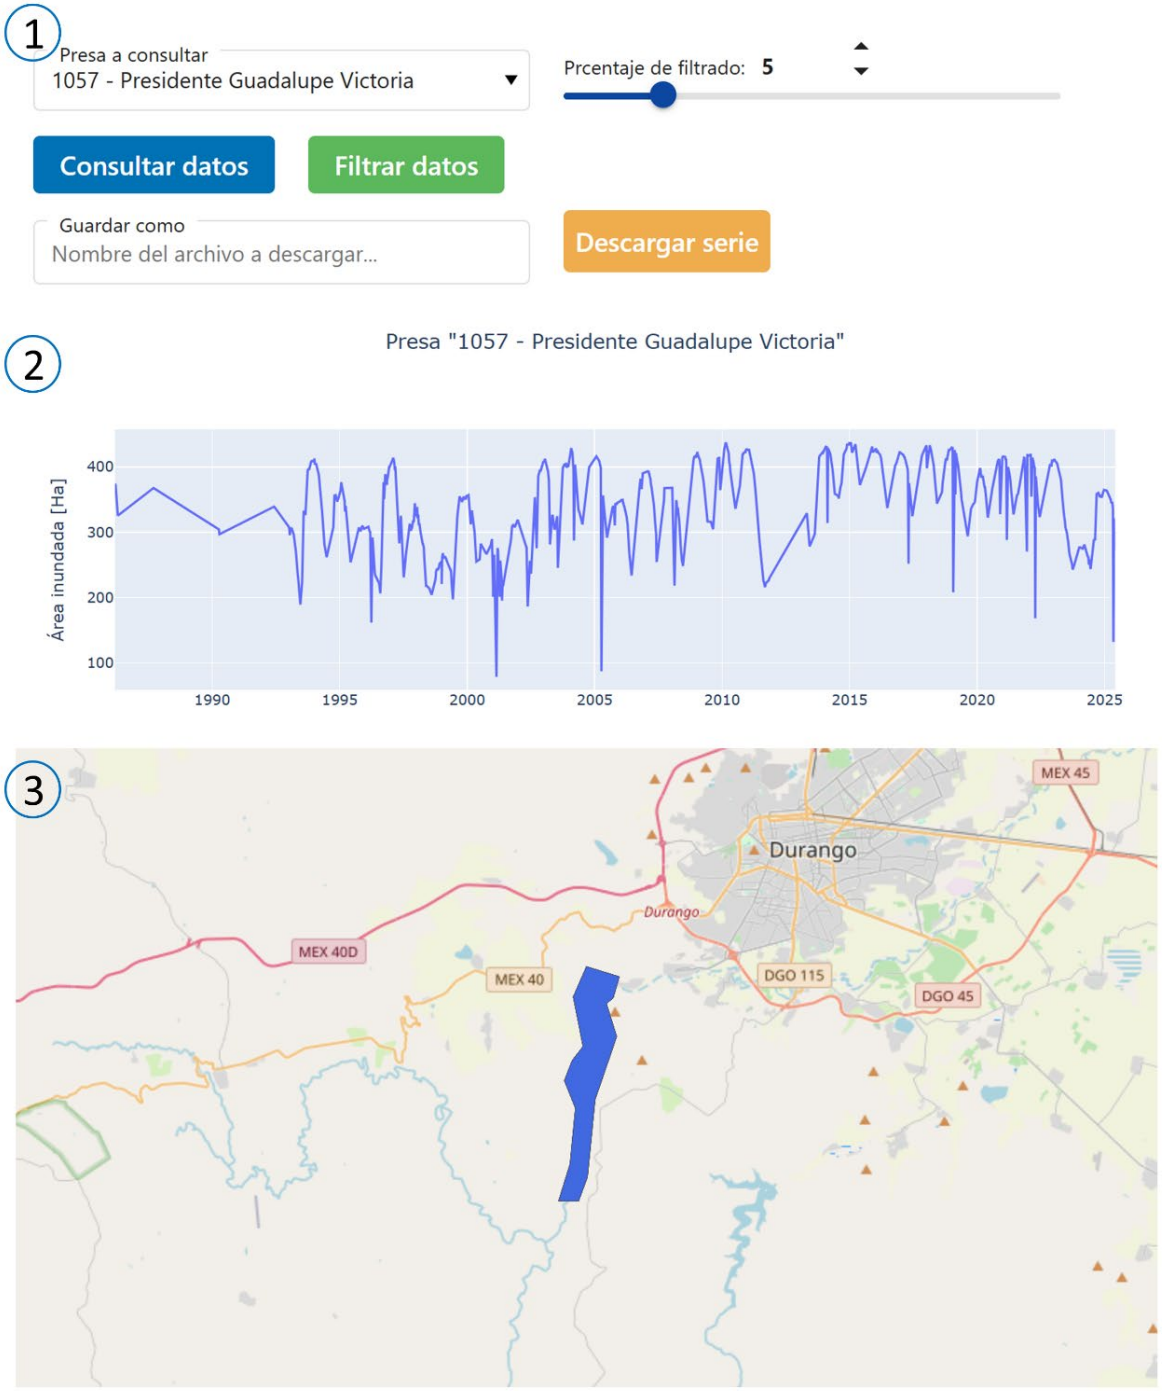


Figura 25. Salida a pantalla de la herramienta de monitoreo.



Figura 26. Resultado del algoritmo del filtro aplicado a los datos.1. Gráfica de datos originales. 2. Gráfica de datos filtrados.

Ejemplos de aplicación

Con el objetivo de mostrar la aplicación de las herramientas de monitoreo desarrolladas se presentan dos casos de estudio.

Caracterización del acuífero "1508" Cuautitlán-Pachuca

A continuación, se presentan las gráficas de las variables de precipitación, humedad del suelo, evapotranspiración, Índice de vegetación de diferencia normalizada (NDVI) y almacenamiento de agua subterránea obtenidas del acuífero "1508" Cuautitlán-Pachuca para el periodo comprendido del 01/01/2010 al 01/01/2023.

En la Figura 27 se muestra la serie de tiempo de la precipitación diaria de la colección CHIRPS, se observan valores que superan los 30 mm por día. Se identificó que durante el año 2021 se presentó un aumento en la cantidad de precipitación sobre el área que cubre el acuífero. En contraste, durante el año 2022 la cantidad de precipitación disminuyó considerablemente, con los valores máximos diarios por debajo de 25 mm por día. Con la gráfica interactiva es posible consultar valores puntuales y seleccionar un periodo y rango de valores específicos para inspeccionar las series con mayor detalle, como se muestra en la Figura 28.

Debido a que algunas variables se encuentran a escala mensual, los datos diarios de precipitación se agregaron a escala mensual para obtener graficas comparativas (Figura 29). A partir de los datos mensuales se aprecia una variación inter-anual bien definida con los meses de mayor precipitación entre junio y octubre, con valores de 100 a más de 200 mm de lluvia acumulada en un mes.

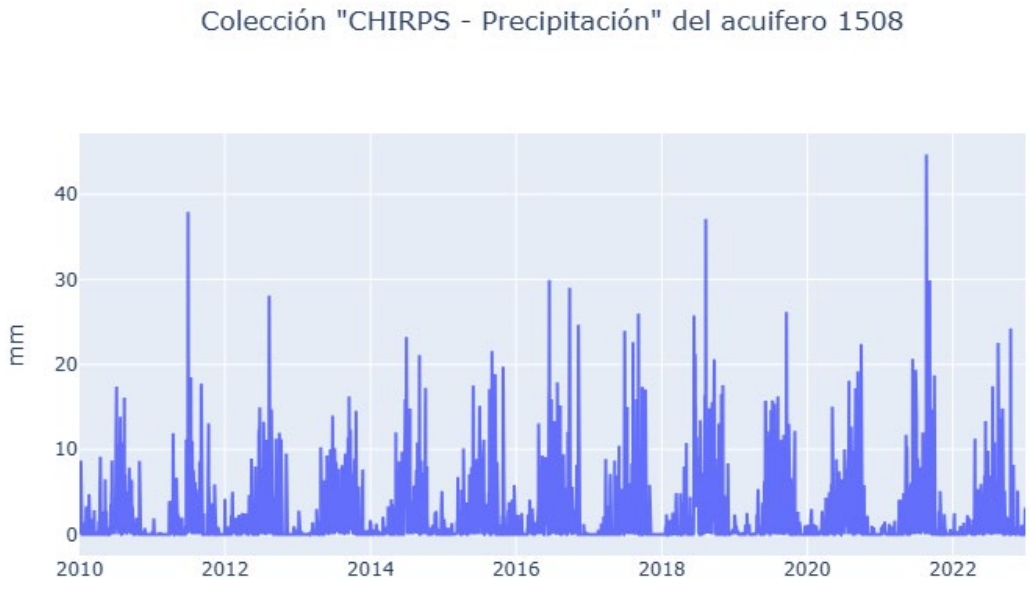


Figura 27. Grafica de la serie de tiempo diaria de la variable de precipitación para el acuífero 1508.

La humedad del suelo, presentada en la Figura 30, muestra incrementos y decrementos significativos, en donde los periodos con mayor humedad coinciden con los años de mayor precipitación, por ejemplo, los años 2011, 2013 y 2021. Mientras que los periodos más secos con menor humedad de suelo se detectaron entre el 2019 y 2020, así como en el 2022 y 2023.

La variable de temperatura máxima (Figura 31) presenta una tendencia creciente, de tal manera que para el año 2022 se presentó el valor más alto de temperatura máxima, superando los 28 °C.

Por su parte, las variaciones del almacenamiento de agua subterránea obtenidas del producto GLDAS 2.2 rondan de los 600 a poco más de 1000 mm, con decrementos debidos al periodo seco del 2020 (Figura 30).

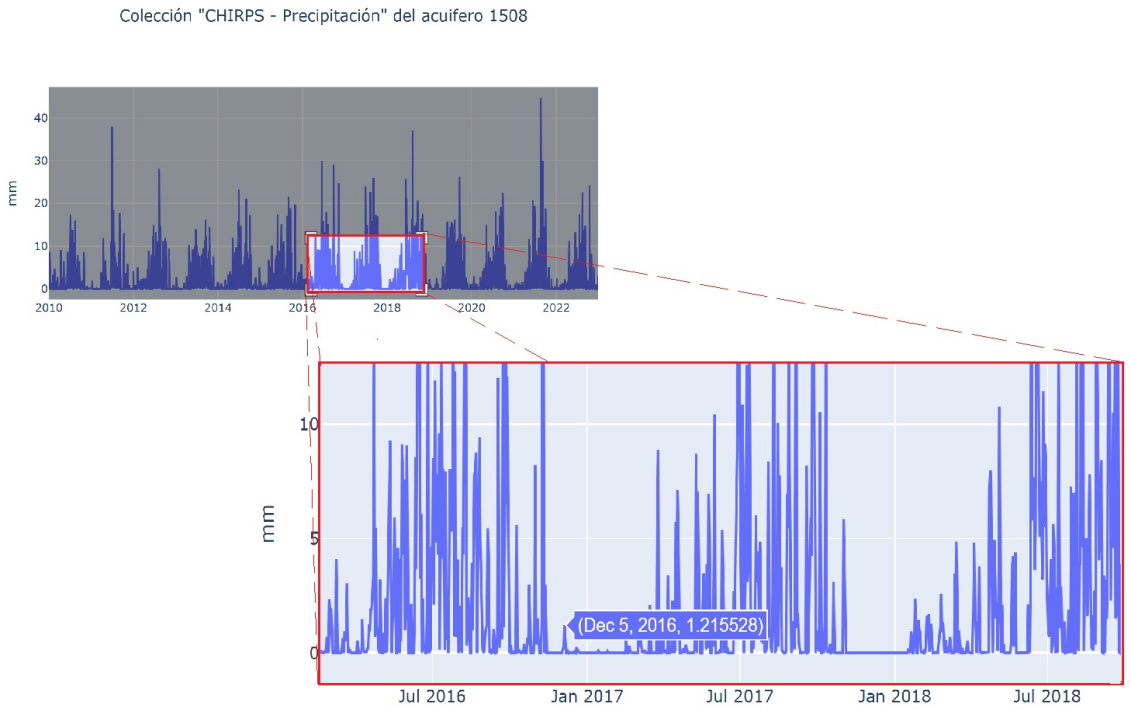


Figura 28. Comportamiento de la gráfica interactiva de la de la Figura 27.



Figura 29. Grafica de la serie de tiempo mensual de la variable de precipitación para el acuífero 1508.

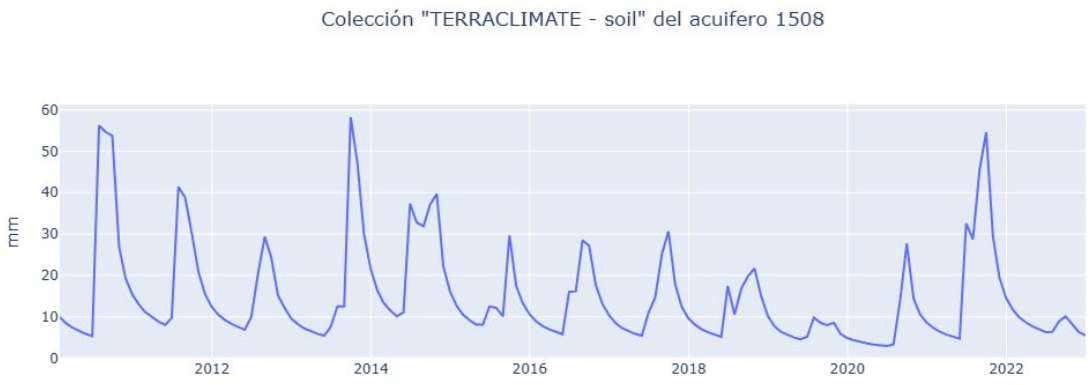


Figura 30. Grafica de la serie de tiempo mensual de la variable de humedad del suelo para el acuífero 1508.

Finalmente, la variabilidad de la vegetación en el acuífero es representada a través del NDVI, el cual presenta los menores valores en el año 2023, lo cual está asociado a la pérdida de biomasa y densidad de la vegetación (Figura 33).

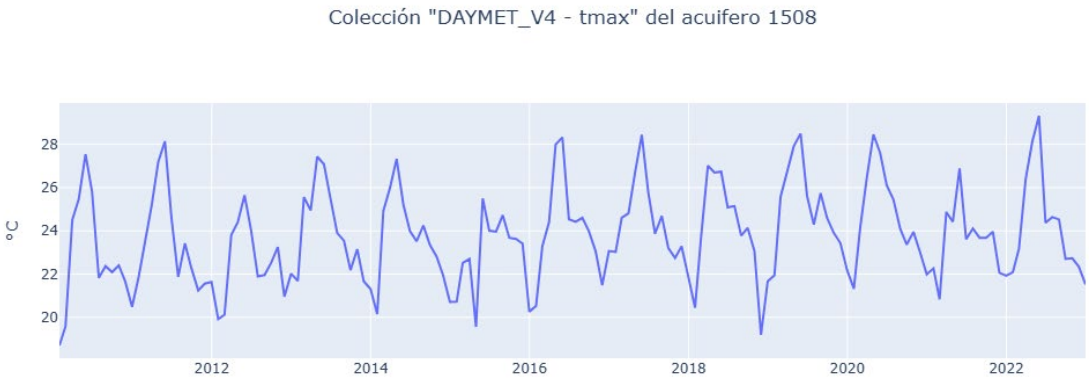


Figura 31. Grafica de la serie de tiempo mensual de la variable de temperatura máxima para el acuífero 1508.

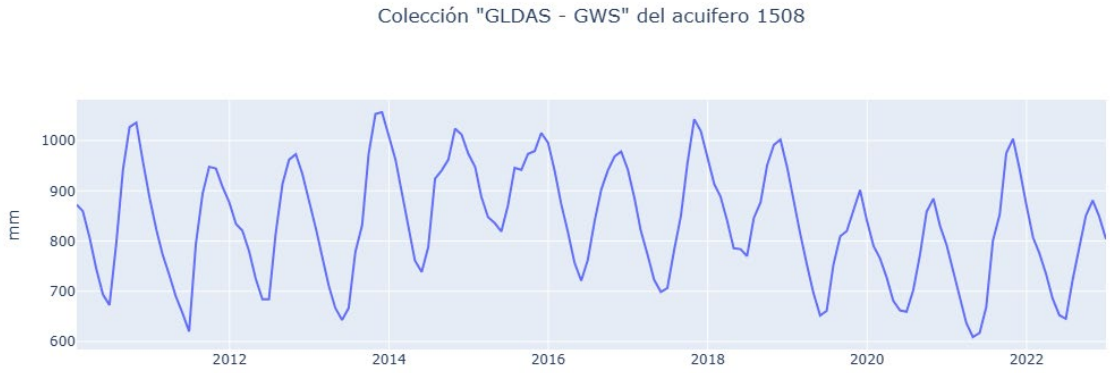


Figura 32. Grafica de la serie de tiempo mensual de la variable de almacenamiento de agua subterránea para el acuífero 1508.

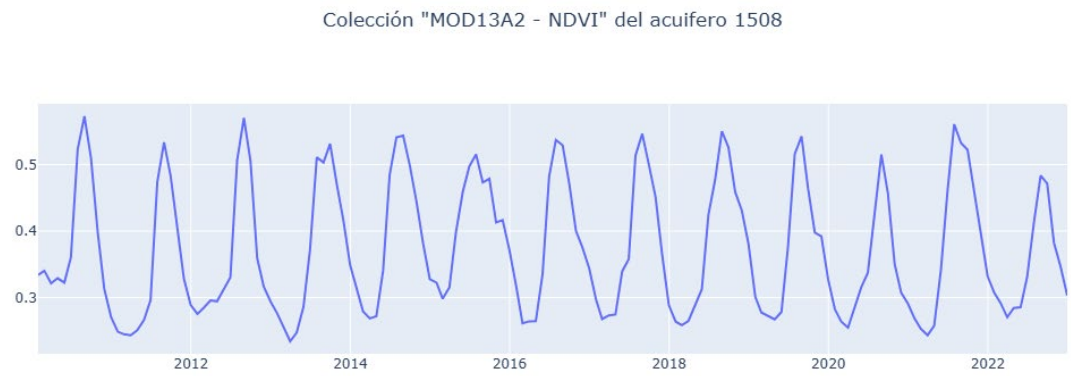


Figura 33. Grafica de la serie de tiempo mensual de la variable de índice de vegetación normalizada para el acuífero 1508.

Variación del almacenamiento de agua en la presa el Cuchillo, Nuevo León

Se muestra en la Figura 34 el comportamiento de los valores de área inundada para la presa “2689” Cuchillo Solidaridad, ubicada en el estado de Nuevo León, en el periodo comprendido entre el año 1985 y septiembre del 2024. Esta presa es una de las principales fuentes de abastecimiento de agua para la ciudad de Monterrey, y en los últimos años se ha reportado una pérdida de almacenamiento en la presa que han derivado en problemas de abastecimiento para la población.

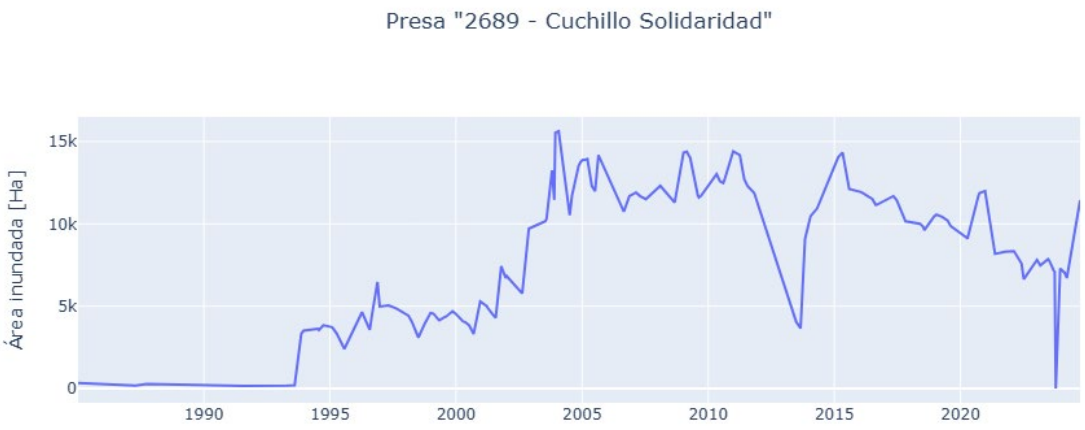


Figura 34. Grafica de la serie de tiempo del valor de área inundada de la presa 2689.

Las primeras fechas del registro consultado muestran valores bajos, con un incremento considerable a partir de 1994. Este cambió abrupto del área inundada se debe a que la presa fue construida en el año 1994, por lo que posterior a esa fecha se observa un aumento general hasta el año 2011. Para el año 2012 se presenta un decremento considerable en el área inundada debido a un periodo de sequía que azotó el norte de México. Para el año 2015 la presa recuperó su almacenamiento, pero desde el 2016 se ha mantenido a la baja. Además, para el año 2024 se observa un valor cero de área inundada.

El cambio abrupto del 2024 fue filtrado para evaluar su consistencia temporal. El resultado del algoritmo del filtro se muestra en la Figura 35, con lo que se comprueba que el área cero observada en 2024 corresponde a un valor atípico derivado del procesamiento de las imágenes satelitales. Aún sin el valor atípico, se comprueba que del 2020 al 2024 el almacenamiento de la presa disminuyó considerablemente, registrando los valores más bajos de los últimos 20 años, sólo superados por el efecto de la sequía del 2011-2012.

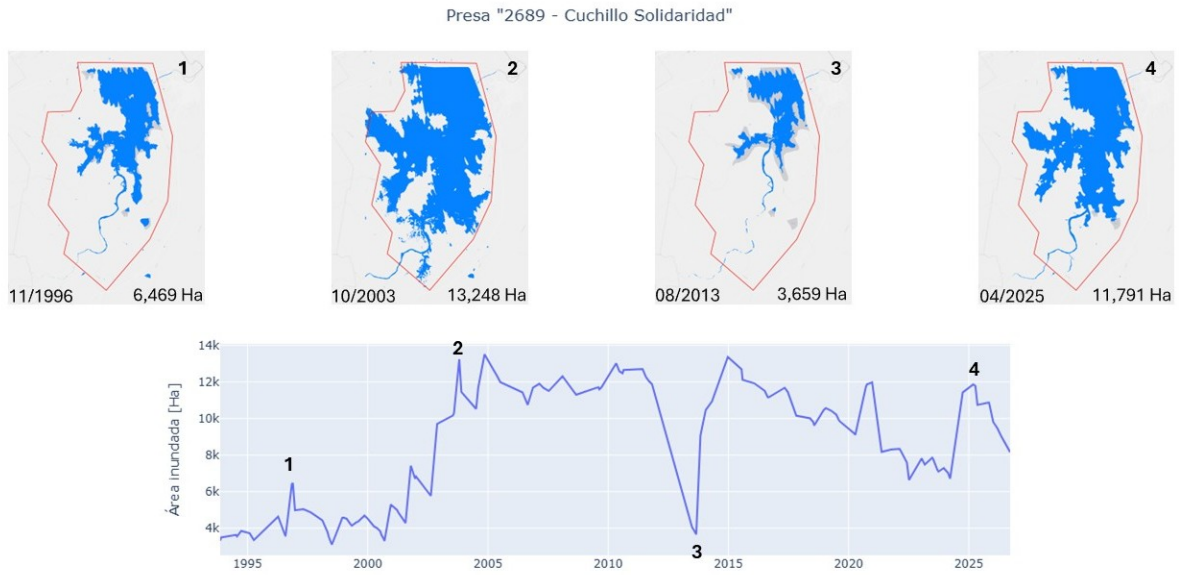


Figura 35. Grafica filtrada de la serie de tiempo y representación geográfica del área inundada de la presa 2689.

Conclusiones

En este trabajo se han desarrollado dos herramientas de monitoreo de recursos hídricos a partir de información satelital y de productos globales. Estas herramientas han sido desarrolladas con librerías de código abierto a partir del lenguaje de programación Python, implementando bases de datos disponibles en la plataforma de cómputo en la nube de Google Earth Engine.

La implementación de herramientas para el monitoreo de recursos naturales es fundamental para garantizar la conservación y el uso sostenible de éstos. Las herramientas computacionales presentadas en este trabajo han demostrado ser eficaces para:

- Monitorear la variabilidad temporal de variables hidro-climatológicas en acuíferos.
- Detectar las variaciones del almacenamiento de agua a partir del área inundada en algunas de las principales presas del país.
- Identificar el efecto de periodos de sequía en la disponibilidad y almacenamiento de agua.

Sin embargo, es importante destacar que la efectividad de estas herramientas depende en gran medida de la calidad y disponibilidad de los datos, así como de la capacidad técnica para analizarlos e integrarlos con otras fuentes de información y sistemas institucionales. Por ello, se recomienda realizar un uso crítico y responsable de la información generada, complementándola y validándola con datos obtenidos directamente en campo. Esta integración permite mejorar la precisión de los análisis, reducir incertidumbres y fortalecer la toma de decisiones basada en evidencia.

Referencias

Astral (2025). *uv*.(Versión 7.14) [Software]. https://github.com/astral-sh/uv.git

Bakker, W. H., van der Meer, F. D., Feringa, W., Parodi, G. N., Gieske, A. S. M., Pohl, C., Gorte, B. G. H., Reeves, C. v, Grabmaier, K. A., van Ruitenbeek, F. J., Hecker, C. A., Schetselaar, E. M., Horn, J. A., Weir, M. J. C., Westinga, E., & Woldai, T. (2009). *Principles of Remote Sensing - An introductory textbook* (K. Tempfli, N. Kerle, G. C. Huurneman, & L. L. F. Janssen, Eds.; Fourth edition). The International Institute for Geo-Information Science and Earth Observation (ITC).

Baur, Oliver & Austen, G. & Keller, W.. (2007). Efficient Satellite Based Geopotential Recovery. 10.1007/978-3-540-36183-1_36.

Centro Nacional de Prevención de Desastres (CENAPRED). (2019). *¿Sabes cuál es la función de las presas?* Gobierno de México. https://www.gob.mx/cenapred/articulos/sabes-cual-es-la-funcion-de-las-presas

Chen, L., & Wang, L. (2018). *Recent advance in earth observation big data for hydrology*. In Big Earth Data, 2(1), p. 86–107. Taylor and Francis Ltd. https://doi.org/10.1080/20964471.2018.1435072

Comisión Nacional del Agua (CONAGUA). (2022). *Estadísticas del Agua en México 2021*. https://files.conagua.gob.mx/conagua/publicaciones/Publicaciones/EAM%202021.pdf

EROS. (2019). *USGS EROS Archive - Sentinel-2 - Comparison of Sentinel-2 and Landsat*. Earth Resources Observation and Science (EROS) Center. https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2-comparison-sentinel-2-and-landsat

GitHub. (2025). *Acerca de GitHub y Git*. Git Hub Inc. https://docs.github.com/es/get-started/start-your-journey/about-github-and-git

Gorelick, N. (2012). *Google Earth Engine*. American Geophisical Union (AGU) Fall Meeting Abstracts, U31A-04. Bibcode: 2012AGUFM.U31A..04G

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). *Google Earth Engine: Planetary-scale geospatial analysis for everyone*. Remote Sensing of Environment. http://dx.doi.org/10.1016/j.rse.2017.06.031

Holoviz. (2025). *Panel* (Versión 1.6.1) [Software]. https://panel.holoviz.org/

Khorram, S., van der Wiele, C.F., Koch, F.H., Nelson, S.A.C., Potts, M.D. (2016). *Principles of Applied Remote Sensing*. Springer Book, p. 1-313. doi:10.1007/978-3-319-22560-9

MathWorks. (2024). *Hyperespectral and Multiespectral Data Correction*. The MathWorks, Inc. https://la.mathworks.com/help/images/hyperspectral-data-correction.html

McCabe, M. F., Rodell, M., Alsdorf, D. E., Miralles, D. G., Uijlenhoet, R., Wagner, W., Lucieer, A., Houborg, R., Verhoest, N. E. C., Franz, T. E., Shi, J., Gao, H., & Wood, E. F. (2017). *The future of Earth observation in hydrology.* Hydrology and Earth System Sciences, 21(7), p. 3879–3914. http McCabe s://doi.org/10.5194/hess-21-3879-2017

McKinney, W. (2011). *pandas: a Foundational Python Library for Data Analysis and Statistics*. Python for High Performance and Scientific Computing.

NASA. (2010). *What is an Orbit?* National Aeronautics and Space Administration, Space Place. https://spaceplace.nasa.gov/orbits/en/

NASA. (2023). *Studying the Earth´s Gravity form Space: The Gravity Recovery and Climate Experiment (GRACE)*. Goddbelt, Maryland. https://grace.jpl.nasa.gov/system/internal_resources/details/original/97_GRACE_Fact_Sheet.pdf

NASA. (2024). *What is Remote Sensing?* National Aeronautics and Space Administration, EARTHDATA Open Access for Open Science. https://www.earthdata.nasa.gov/learn/backgrounders/remote-sensing

NASA ARSET. (2023). *Fundamentos de Teledetección (Percepción Remota).* National Aeronautics and Space Administration, Applied Remote Sensing Training Program. https://appliedsciences.nasa.gov/sites/default/files/2023-02/Fundamentals_of_RS_Span.pdf

Navidi, W. (2006). Estadística para ingenieros. McGraw Hill. p. 868.

Ndehedehe, C. (2022). *Satellite Remote Sensing of Terrestrial Hydrology*. Springer Cham. https://doi.org /10.1007/978-3-030-99577-5

Ngamile, S., Madonsela, S., & Kganyago, M. (2025). *Trends in remote sensing of water quality parameters in inland water bodies: a systematic review.* Frontiers in Environmental Science, vol. 13. https://doi.org/10.3389/fenvs.2025.1549301

Orynbaikyzy, A., Gessner, U., Mack, B., & Conrad, C. (2020). *Crop type classification using fusion of sentinel-1 and sentinel-2 data: Assessing the impact of feature selection, optical data availability, and parcel sizes on the accuracies*. Remote Sensing, 12(17), p. 2779. https://doi.org/10.3390/RS12172779

Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). *Sentinel-2 Data for Land Cover / Use Mapping: A Review*. Remote Sensing, 2291(12), p. 14. https://doi.org/10.3390/rs12142291

Project Jupyter. (2024). *JupyterLab* (Versión 3.0.0) [Software]. https://jupyter.org

Python (2024). *Glosario*. Entorno virtual. Python Software Foundation. https://docs.python.org/es/3.13/glossary.html#term-virtual-environment

Python (2024). *Python: About.* Python Software Foundation. https://www.python.org/about/

Ramírez-Arias, J.L. (2019). *Radiología e imagen.* Revista de la Facultad de Medicina (México), 68(3), p. 7-14. https://doi.org/10.22201/fm.24484865e.2019.62.2.03

Ronan, P. (2008). *Espectro de las ondas Electromagnéticas*. Wikipedia Commons. https://commons.wikimedia.org/wiki/File:EM_spectrum_es.svg

Salas, C. P. (2017). *Estimación de la deformación en la falla imperial durante 2014-2016 en el valle de Mexicali mediante GPS y microgravimetría.* Tesis para obtener el grado de maestro en ciencias. Universidad Autónoma de Baja California, Instituto de Ingeniería. https://repositorioinstitucional.uabc.mx/entities/publication/bfe59514-8120-4011-83fb-58b064a85399

Sergieieva, K. (2023). *Tipos De Satélites: Sus Órbita Y Funciones*. EOS Data Analytics. https://eos.com/es/blog/tipos-de-satelites/

Serway R.A., Jewett J.W. (2009). *Física para ciencias e ingeniería con física moderna.* Cenagage Learing Editores, p. 966 – 968.

Sheffield, J., Wood, E. F., Pan, M., Beck, H., Coccia, G., Serrat-Capdevila, A., & Verbist, K. (2018). *Satellite Remote Sensing for Water Resources Management: Potential for Supporting Sustainable Development in Data-Poor Regions*. Water Resources Research, 54(12), p. 9724–9758. https://doi.org/10.1029/2017wr022437

Solórzano V. y Perilla G. (2022). *Cómo usar Google Earth Engine y no fallar en el intento*. Centro de Investigaciones en Geografía Ambiental, UNAM. https://doi.org/10.22201/ciga.9786073066969e.2022

Su, Z., Roebeling, R. A., Schulz, J., Holleman, I., Levizzani, V., Timmermans, W. J., Rott, H., Mognard-Campbell, N., de Jeu, R., Wagner, W., Rodell, M., Salama, M. S., Parodi, G. N., & Wang, L. (2011). *2.14 - Observation of Hydrological Processes Using Remote Sensing.* In P. Wilderer (Ed.), Treatise on Water Science, vol. 2, p. 351–399. https://doi.org/https://doi.org/10.1016/B978-0-444-53199-5.00042-7

Telford, W. M., Geldart, L. P. & Sheriff, R. E. (1990). ”Applied Geophysics” Cambridge University, USA. 2da edición.

Tucker, C. J. (1979). *Red and photographic infrared linear combinations for monitoring vegetation*. Remote Sensing of Environment, 8(2), p. 127–150. https://doi.org/10.1016/0034-4257(79)90013-0

Wu, Q. (2023). “Earth Engine and Geemap. Geospatial Data Science with Python.” Locate Press. https://locatepress.com/book/gee