

# Herramientas digitales para la teledetección de inundaciones en el estado de Colima utilizando imágenes satelitales

**RESUMEN:** Las inundaciones son uno de los desastres naturales más comunes en el estado de Colima, causando significativas pérdidas económicas y afectando gravemente a la población local. La frecuencia y el impacto de las inundaciones subrayan la necesidad de implementar estrategias efectivas de gestión de riesgos y medidas de mitigación para minimizar sus efectos adversos en la comunidad.

Este artículo examina el uso de herramientas digitales para la teledetección de inundaciones, integrando datos de los satélites Sentinel-1 (SAR) y CHIRPS (Climate Hazards Group Infrared Precipitation with Stations) en el contexto del huracán Patricia de 2015. Se utilizó Google Earth Engine para procesar las imágenes satelitales, aplicar algoritmos de inteligencia artificial y validar los resultados mediante observaciones in situ.

Los resultados revelan una correlación significativa entre las áreas inundadas detectadas por el satélite Sentinel-1 y los patrones de precipitación extrema registrados por CHIRPS. La integración de datos satelitales y de precipitación proporciona una visión más completa y precisa de las dinámicas de inundación, lo que es crucial para desarrollar estrategias de mitigación y respuesta ante desastres naturales. Este enfoque permite a los responsables de la gestión de riesgos tomar decisiones informadas y proactivas para proteger a las comunidades vulnerables.

**PALABRAS CLAVE:** CHIRPS, Google Earth Engine, huracán, inundaciones, teledetección, Sentinel-1.



## Colaboración

Raúl U. Rentería Flores, Raúl T. Aquino Santos, Jesús López de la Cruz, Universidad de Colima; Joan Saladich Cubero, Geoskop Climate Intelligence

Fecha de recepción: 29 de septiembre 2025

Fecha de aceptación: 12 de noviembre de 2025

**ABSTRACT:** Floods are one of Colima's most common natural disasters, causing significant economic losses and severely impacting the local population. The frequency and impact of flooding underscore the need to implement effective risk management strategies and mitigation measures to minimize their adverse effects on the community. This article examines digital tools for flood remote sensing, integrating data from the Sentinel-1 (SAR) and Climate Hazards Group Infrared Precipitation with Stations (CHIRPS) satellites in the context of Hurricane Patricia in 2015. Google Earth Engine processed the satellite images, applied artificial intelligence algorithms, and validated the results through in-situ observations.

The results reveal a significant correlation between flooded areas detected by the Sentinel-1 satellite and extreme precipitation patterns recorded by CHIRPS. Integrating satellite and precipitation data provides a more complete and accurate view of flood dynamics, crucial for developing mitigation and response strategies for natural disasters. This approach enables risk managers to make informed and proactive decisions to protect vulnerable communities.

**KEYWORDS:** Floods, remote sensing, Sentinel-1, CHIRPS, Hurricane Patricia, Google Earth Engine.

## INTRODUCCIÓN

Las inundaciones representan una de las amenazas naturales más recurrentes y costosas a nivel mundial, afectando múltiples dimensiones del bienestar humano como la salud, la seguridad alimentaria, la economía y la infraestructura [1] [2]. Estos eventos naturales no solo resultan en la pérdida de vidas humanas, sino que también provocan daños extensos a la infraestructura, generan consecuencias económicas devastadoras y tienen efectos a largo plazo que frecuentemente derivan en repercusiones sociales adversas [3]. La magnitud de estos impactos subraya la necesidad urgente de desarrollar estrategias efectivas de gestión de riesgos y medidas de mitigación para minimizar sus efectos negativos en las comunidades afectadas.

Las inundaciones repentinas son particularmente peligrosas debido a su naturaleza impredecible y la rapidez con la que pueden desarrollarse. Estas inundaciones suelen ocurrir sin previo aviso y pueden ser provocadas por tormentas eléctricas estacionarias, tormentas que afectan repetidamente la misma área, o precipitaciones intensas asociadas con huracanes y tormentas tropicales [4]. La falta de tiempo para prepararse ante estos eventos aumenta el riesgo para las comunidades afectadas, subrayando la necesidad de sistemas de alerta temprana y estrategias de respuesta rápida para mitigar sus impactos.

Numerosas investigaciones han examinado los efectos y la evaluación de los daños causados por fenómenos hidrometeorológicos extremos, así como por eventos de origen humano y natural [6-9]. Un informe de 2022 destacó que los ciclones tropicales fueron responsables del 51% de las afectaciones por desastres naturales en México, seguidos por las lluvias e inundaciones, que representaron el 26%, y los sismos, con un 11% [10]. Estos datos subrayan la importancia de desarrollar estrategias de mitigación y respuesta ante desastres, especialmente en regiones vulnerables a estos fenómenos.

Estos eventos han aumentado significativamente la vulnerabilidad de las poblaciones afectadas, especialmente en regiones como Colima. En 2015, el huracán Patricia provocó precipitaciones extremas que superaron los 400 mm en un período de 72 horas, resultando en inundaciones catastróficas [8]. La magnitud de estas lluvias y sus consecuencias subrayan la necesidad urgente de implementar medidas de mitigación y estrategias de gestión de riesgos para proteger a las comunidades vulnerables y minimizar los impactos de futuros eventos similares.

En este contexto, la teledetección mediante imágenes satelitales se ha consolidado como una estrategia esencial para la vigilancia y predicción de eventos hidrometeorológicos extremos.

La integración de plataformas digitales como Google Earth Engine, junto con los datos de los satélites Sentinel-1 (SAR) y productos de precipitación como CHIRPS, ha optimizado la capacidad de respuesta ante emergencias y fortalecido las estrategias de mitigación de riesgos [11-14].

Este enfoque permite a los responsables de la gestión del riesgo anticipar y reaccionar de manera más efectiva, minimizando los impactos negativos en comunidades vulnerables y mejorando la planificación de medidas preventivas.

En los últimos años, los avances en inteligencia artificial (IA) y aprendizaje profundo (deep learning) han ampliado significativamente las posibilidades de análisis dentro de la teledetección.

El uso de modelos como las redes neuronales convolucionales (CNN) y arquitecturas derivadas como U-Net permite identificar y segmentar automáticamente las áreas afectadas por inundaciones, extrayendo patrones espaciales complejos de datos radar (Sentinel-1) y de precipitación (CHIRPS) [29] [30].

Estos enfoques superan las limitaciones de los métodos tradicionales de umbralización o clasificación supervisada, ofreciendo resultados más precisos y confiables incluso bajo condiciones de nubosidad o baja visibilidad.

De esta forma, la combinación de teledetección satelital e inteligencia artificial mejora la detección oportuna de áreas inundadas, reduce los tiempos de procesamiento y refuerza la capacidad predictiva de plataformas en la nube como Google Earth Engine [18].

En este estudio se aborda el análisis de las inundaciones generadas por el huracán Patricia en Colima, integrando tres componentes principales:

1. Detección de áreas inundadas mediante imágenes SAR de Sentinel-1.
2. Validación con datos de precipitación del producto CHIRPS.
3. Evaluación de la efectividad de estas herramientas para la gestión de riesgos hídricos.

La metodología propuesta no solo contribuye a comprender eventos pasados, sino que también establece un marco de referencia para el desarrollo de sistemas de alerta temprana más robustos en zonas tropicales propensas a inundaciones repentinas [5,17].

## MATERIAL Y MÉTODOS

Herramientas digitales para la detección de inundaciones mediante imágenes satelitales. El uso de herramientas digitales para la teledetección de inundaciones ha experimentado una evolución notable en los últimos años, mejorando significativamente la capacidad para analizar grandes volúmenes de datos satelitales. Estas tecnologías avanzadas permiten la generación de mapas precisos que identifican las áreas afectadas por inundaciones, facilitando una respuesta más efectiva ante desastres naturales. A continuación, se destacan algunas de las herramientas más relevantes que han sido fundamentales para este propósito, proporcionando a los responsables de la gestión de riesgos la información necesaria para tomar decisiones informadas y proactivas.

### Satélites Sentinel-1

Los satélites Sentinel proporcionan imágenes de alta resolución que son fundamentales para el monitoreo de inundaciones.

Sentinel-1: Radar de apertura sintética (SAR), puede observar la superficie terrestre bajo cualquier condición climática (día/noche, nubes).[11].

Este estudio se centró exclusivamente en imágenes SAR proporcionadas por Sentinel-1, dada su capacidad para detectar cuerpos de agua bajo condiciones climáticas adversas como nubosidad o lluvia intensa.

### Inteligencia artificial y aprendizaje automático

La implementación de técnicas de inteligencia artificial ha revolucionado la detección de inundaciones. Modelos de aprendizaje profundo como las Redes U-Net han demostrado ser altamente eficaces en la segmentación automática de zonas afectadas por inundaciones [12].

Además, aunque los algoritmos de inteligencia artificial pueden procesar imágenes rápidamente, la detección de cuerpos de agua no ocurre en tiempo real. Los satélites como Sentinel-1 tienen revisita cada 6 a 12 días, y sus datos requieren procesamiento posterior. [11]. La integración de datos satelitales con información proveniente de estaciones hidrometeorológicas locales contribuye a desarrollar modelos predictivos más robustos [17].

### CHIRPS: Datos Híbridos de Precipitación

CHIRPS es un producto de precipitación cuasi-global desarrollado por el Climate Hazards Center de la Universidad de California Santa Barbara en colaboración con la NASA. Combina múltiples fuentes de datos para proporcionar estimaciones de precipitación confiables, especialmente en regiones con escasas estaciones meteorológicas [18].

### Características técnicas:

- Resolución espacial: 0.05° (~5.5 km) desde 1981 hasta presente
- Cobertura temporal: Datos diarios, pentadales y mensuales
- Fuentes de datos:
  - Imágenes satelitales infrarrojas (GOES, Meteosat)
  - Mediciones in situ de estaciones meteorológicas globales (GHCN, GSOD)
  - Reanálisis climáticos (NOAA-CPC)

### Desafíos y Oportunidades

El desarrollo e implementación de herramientas digitales para la detección de inundaciones presentan diversos desafíos y oportunidades. Es fundamental evaluar estos factores para garantizar la efectividad de las soluciones tecnológicas en la gestión de riesgos hídricos.

### Desafíos

Limitaciones de resolución temporal y espacial  
Aunque Sentinel-1 (SAR) opera bajo cualquier condición atmosférica, su frecuencia de revisita (6 a 12 días) puede no ser suficiente para monitoreo en tiempo cuasi-real [18].

### Acceso y calidad de datos

En regiones con escasa cobertura de estaciones meteorológicas, como zonas rurales de Colima, validar datos satelitales puede ser complicado [21]. Además, aunque hay productos abiertos como Sentinel o CHIRPS, otros

de alta resolución como PlanetScope son comerciales, lo cual limita su acceso en investigaciones públicas.

Validación limitada de resultados

### Validación limitada de resultados

La ausencia de datasets validados por instituciones gubernamentales, como mapas de zonas de riesgo actualizados, limita la capacidad de evaluar el rendimiento de los modelos de detección [1]. Esto impacta especialmente en áreas sin infraestructura de monitoreo hidrológico permanente.

### Limitaciones de los modelos de aprendizaje automático

Modelos como Random Forest (RF) presentan dificultades para manejar datos secuenciales y condiciones climáticas variables [23]. Asimismo, redes neuronales como LSTM son susceptibles al sobreajuste (overfitting) si no se emplean técnicas como regularización, validación cruzada o dropout [18]. Aunque el sobreajuste es un riesgo común en IA, puede mitigarse mediante diseño cuidadoso del modelo.

### Requisitos de infraestructura y personal capacitado

Procesar imágenes SAR con SNAP o plataformas similares requiere hardware especializado y conocimientos técnicos en programación geoespacial [17]. Esto representa un obstáculo para muchas instituciones públicas locales que carecen de recursos o personal formado en estos aspectos.

### Oportunidades

#### Modelos híbridos y de transferencia

El desarrollo de enfoques como RF + LSTM permite combinar interpretabilidad y capacidad predictiva secuencial, optimizando el análisis de inundaciones [23-25]. Además, el transfer learning ha demostrado ser útil para adaptar modelos a regiones con baja disponibilidad de datos históricos [18].

### Procesamiento en la nube y democratización tecnológica

Plataformas como Google Earth Engine [26] eliminan la necesidad de computadoras locales de alto rendimiento, permitiendo a investigadores y gobiernos acceder a datos satelitales y herramientas analíticas desde cualquier navegador web.

## METODOLOGÍA

### Diseño metodológico general

La metodología se centra en el análisis satelital multi-fuente mediante la técnica de detección activa (radar), integrada en una plataforma de procesamiento en la nube.

Se utilizaron datos de los satélites Sentinel-1 (SAR) y CHIRPS (precipitación), procesados mediante Google Earth Engine (GEE). El objetivo fue cuantificar áreas afectadas por inundación y correlacionarlas con eventos de precipitación extrema. Además, se revisaron estudios previos y se contrastaron los resultados con datos secundarios para validar la estrategia metodológica.



## Área de estudio y periodo de análisis

El área de estudio corresponde al estado de Colima, una región tropical ubicada en el occidente de México con alta exposición a fenómenos hidrometeorológicos. Se delimitó espacialmente utilizando una colección administrativa (FeatureCollection) filtrada por entidad federativa. El periodo de análisis se concentró entre el 1 y el 31 de octubre de 2015, periodo en que impactó el huracán Patricia.

## Procesamiento de datos satelitales

### • Sentinel-1 (Radar SAR)

Se utilizaron productos Sentinel-1 GRD (Ground Range Detected) en modo IW (Interferometric Wide Swath), con polarización VV (vertical-vertical), adecuados para el análisis de cuerpos de agua bajo condiciones climáticas adversas. El procesamiento se realizó en GEE, con las siguientes etapas:

• Preprocesamiento: aplicación de filtro speckle para reducción de ruido, calibración radiométrica a decibelios y corrección geométrica usando el modelo digital de elevación SRTM.

• Análisis de cambio: se calcularon imágenes de diferencia entre el periodo pre-evento (1-15 oct) y post-evento (24 oct-7 nov). Se aplicó una umbralización de 1.5 dB para identificar áreas con cambios abruptos, clasificando los píxeles como agua/no agua. El umbral de 1.5 dB se adoptó con base en valores reportados en estudios, donde diferencias superiores a este rango se asocian con cambios súbitos de retrodispersión relacionados con inundación [27][28].

• Cálculo de área: mediante álgebra de píxeles, se estimó la superficie inundada en km<sup>2</sup>. El resultado se exportó en formato GeoTIFF para análisis complementario en QGIS.

## CHIRPS (precipitación)

Los datos diarios de precipitación se obtuvieron del producto UCSB-CHG/CHIRPS/DAILY (resolución espacial 0.05°, ~5.5 km). Se filtró el periodo del 20 al 25 de octubre de 2015 y se calcularon acumulados y máximos diarios.

Posteriormente, se generaron mapas de isolíneas y se superpusieron con las capas de inundación derivadas de Sentinel-1 para evaluar coincidencias espaciales y temporales. Este cruce permitió relacionar directamente eventos extremos de precipitación con las zonas afectadas por inundaciones.

Procesamiento computacional y herramientas utilizadas

El procesamiento se realizó casi en su totalidad mediante Google Earth Engine, aprovechando su capacidad de cálculo en la nube y la disponibilidad de datos satelitales de libre acceso [26]. La herramienta SNAP de la ESA se utilizó como referencia para validación de parámetros en imágenes Sentinel-1, aunque no fue implementada directamente en este estudio.

Los resultados se exportaron para su análisis posterior en QGIS (sistema de información geográfica de código abierto) y en Python para generar gráficas de precipitación diaria y acumulada.

Validación cruzada y comparación con estudios previos  
Para validar los resultados, se compararon las áreas identificadas como inundadas con reportes del CENAPRED sobre los impactos del huracán Patricia en Colima. Además, se contrastaron los mapas generados con registros históricos de precipitación e imágenes publicadas en literatura académica sobre eventos similares [6][8].

Si bien no se contó con validación in situ, la correlación entre zonas con alta precipitación ( $\geq 106$  mm) y las áreas clasificadas como inundadas en radar respalda la confiabilidad metodológica.

## RESULTADOS

### Google Earth Engine con Sentinel-1

En la Figura 1 se muestra el primer flujo para el tratamiento de imágenes Sentinel-1 (SAR) y Sentinel-2 (óptico), destacando que para este estudio solamente usamos Sentinel-1 desde su carga en Google Earth Engine (GEE), hasta la fusión de resultados para crear mapas de inundación en QGIS.

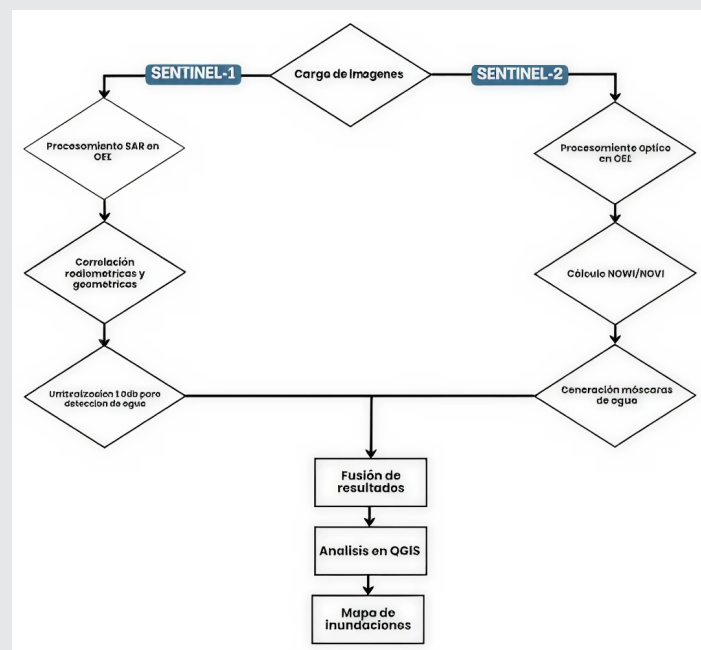


Figura 1. Diagrama de flujo para imágenes Sentinel-1 y Sentinel-2.

Fuente: Elaboración propia.

A continuación, se presenta una explicación paso a paso del código de Google Earth Engine diseñado para calcular las áreas inundadas en Colima, México, a partir de imágenes de satélite de Sentinel-1 tras el paso del huracán Patricia en 2015.

Primero se define la región de interés usando un conjunto de características (Feature Collection) que representa

divisiones administrativas. En este caso, se filtra para seleccionar el estado de Colima, como se puede observar en la Figura 2.

```
// Definir la región de interés (Colima, México)
var colima = ee.FeatureCollection("FAO/GAUL/2015/level2")
    .filter(ee.Filter.eq('ADM2_NAME', 'Colima'))
    .filter(ee.Filter.eq('ADM1_NAME', 'Colima'));
```

Figura 2. Definición del área de interés

Fuente: Elaboración propia.

Después se procede a hacer una carga de colección de imágenes de radar de la misión Sentinel-1. Se filtra por ubicación (dentro de Colima), fechas (del 1 al 15 de octubre de 2015), modo de instrumento (IW) y polarización (VV), como se puede observar en la Figura 3.

```
var prevEventCollection = ee.ImageCollection(
    COPENIGUS/S1,GRD')
    .filterBounds('colima', '2015-10-15')
    .filterDate(colima),
    .filter(ee.Filter.eq('transmitterRecepsacion', 'VV'))
    .select('V')
    .median();
var postEventCollection = ee.ImageCollection(
    COPENIGUS/S1,GRD')
    .filterBounds('colima', '2015-11-07')
    .filterDate(colima),
    .filter(ee.Filter.eq('transmitterRecepsacion', 'VV'))
    .select('V')
    .median();
```

Figura 3. Carga de imágenes Sentinel-1 antes y después del evento.

Fuente: Elaboración propia.

El siguiente paso es verificar si existen hay bandas disponibles en las colecciones de imágenes antes y después del evento. Si no hay bandas, se asigna una imagen con valor cero, Figura 4.

```
// Verificar si hay imágenes disponibles
var preEvent = preEventCollection.bandNames().size().gt(0) ? preEventCollection : ee.Image(0);
var postEvent = postEventCollection.bandNames().size().gt(0) ? postEventCollection : ee.Image(0);
```

Figura 4. Verificación de bandas disponibles.

Fuente: Elaboración propia.

Después de ello se calcula la diferencia entre las imágenes post y pre-evento. Se usa un umbral (1.5) para identificar áreas que han cambiado significativamente (indicando inundación), como se puede observar en la Figura 5.

```
// Calcular la diferencia solo si ambas imágenes están disponibles
var diff = ee.Image(ee.Algorithms.If(
    preEvent.bandNames().size().gt(0).and(postEvent.bandNames().size().gt(0)),
    postEvent.subtract(preEvent).gt(1.5), // Ajustar umbral si es necesario
    ee.Image(0)
));
```

Figura 5. Cálculo de la diferencia entre imágenes.

Fuente: Elaboración propia.

Después de realizar el cálculo, ahora se procede a centrar el mapa en la región de Colima y se añaden las áreas inundadas al mapa, utilizando una paleta de color rojo para visualizarlas, como se puede observar en la Figura 6.

```
// Recortar la imagen a la región de Colima
var floodedAreas = diff.clip(colima);

// Visualizar las áreas inundadas
Map.centerObject(colima, 10);
Map.addLayer(diff.updateMask(diff), {palette: 'blue'}, 'Áreas Inundadas');
Map.addLayer(floodedAreas.updateMask(floodedAreas), {palette: 'red'}, 'Áreas Inundadas Colima');
```

Figura 6. Recorte de la imagen al estado de colima.

Fuente: Elaboración propia.

Ahora se procede a multiplicar la imagen de diferencia (donde se indica inundación) por el área de cada píxel

para obtener el área total inundada. Luego, se suma el área en la región de Colima. Después se obtiene el valor del área inundada en metros cuadrados y se convierte a kilómetros cuadrados. Se maneja la posibilidad de que no haya datos (asignando cero si es necesario), Figura 7.

```
// Calcular el área total inundada en km²
var pixelArea = diff.multiply(ee.Image.pixelArea());
var areaFlooded = pixelArea.reduceRegion({
    reducer: ee.Reducer.sum(),
    geometry: colima,
    scale: 30,
    maxPixels: 1e9
});

// Manejar el caso donde no hay áreas inundadas
var areaFloodedKm2 = ee.Number(areaFlooded.get('VV')).divide(1e6).getInfo() || 0;
print('Área inundada en km²:', areaFloodedKm2);
```

Figura 7. Cálculo del área total inundada en km².

Fuente: Elaboración propia.

Por último, se exporta la imagen recortada a formato GeoTIFF para poderlo procesar con otro programa gestor de mapas como Qgis, en la Figura 8 se puede observar el código.

```
// Exportar la imagen recortada como GeoTIFF
Export.image.toDrive({
    image: floodedAreas,
    description: 'Áreas_Inundadas_Colima',
    scale: 30,
    region: colima.geometry(),
    fileFormat: 'GeoTIFF',
    maxPixels: 1e9
});
```

Figura 8. Exportar la imagen como GeoTIFF.

Fuente: Elaboración propia.

La Figura 9 muestra el resultado final de las áreas inundadas por el huracán Patricia en 2015. Este código utiliza imágenes de radar de Sentinel-1 para calcular y visualizar las áreas inundadas en Colima tras el huracán Patricia, lo que permite a los investigadores y a los responsables de la toma de decisiones evaluar el impacto de desastres naturales y planificar respuestas adecuadas.

Las áreas marcadas en azul corresponden a los píxeles inundados en los alrededores del estado de Colima y las imágenes de color rojo son del estado de Colima.




Figura 9. Áreas inundadas en Colima .

Fuente: Elaboración propia.



El análisis con imágenes Sentinel-1 en Google Earth Engine reveló:

## 1. Áreas inundadas detectadas:

- Se identificaron 142 km<sup>2</sup> de superficie inundada en Colima tras el huracán Patricia (octubre 2015).

## 2. Metodología clave:

- Comparación de imágenes SAR pre-evento (1-15 oct) y post-evento (24 oct-7 nov).
- Umbral de detección: 1.5 dB en diferencia de retrodispersión VV.
- Resolución espacial: 30 metros (precisión para mapeo municipal).

## 3. Productos generados:

- Mapa GeoTIFF de áreas inundadas (descargable para QGIS/ArcGIS).
- Cuantificación exacta del área afectada en km<sup>2</sup>.

## 4. Validación:

- Los resultados coincidieron con:
  - Reportes oficiales de CENAPRED [8]
  - Datos de precipitación extrema de CHIRPS (105.97 mm/día)

## Datos CHIRPS con Google Earth Engine y Python

A continuación, se presenta una explicación paso a paso del código de Google Earth Engine para descarga de datos de CHIRPS tras el paso del huracán Patricia en 2015, para después analizarlos con Python.

Primero se define la región de interés usando un conjunto de características (Feature Collection) que representa divisiones administrativas. En este caso, se filtra para seleccionar el estado de Colima, como se puede observar en la Figura 10.

### • Coordenadas:

- Esquina suroeste: -104.58° Lon, 18.96° Lat
- Esquina noreste: -103.60° Lon, 19.45° Lat

Nota: Este filtro espacial es clave para optimizar el procesamiento.

```
// 1. Definir la región de Colima (bounding box aproximado)
var colima = ee.Geometry.Rectangle([-104.58, 18.96, -103.60, 19.45]);
```

Figura 10. Definición del área de interés.

Fuente: Elaboración propia.

Después se procede a hacer una carga de colección de imágenes de UCSB-CHG/CHIRPS/DAILY (datos diarios de precipitación), para la carga de datos se filtró por la fecha del mes en el cual llegó el Huracán Patricia, como se observa en la Figura 11.

```
// 1. Definir la región de Colima (bounding box aproximado)
var colima = ee.Geometry.Rectangle([-104.58, 18.96, -103.60, 19.45]);

// 2. Cargar y filtrar CHIRPS Daily por fecha y región
var dataset = ee.ImageCollection('UCSB-CHG/CHIRPS/DAILY')
    .filter(ee.Filter.date('2015-10-01', '2015', '2015-10-31'))
    .filterBounds(colima); // [filtro clavé para para Colima]

var precipitation = dataset.select('precipitation');

// 3. Parámetros de visualización
var precipitationVis = {
  min: 1,
  max: 17,
  palette: ['001137', '0aable', 'e7eb05', 'ffa42d', 'e90000'];
};
```

Figura 11. Carga de los datos CHIRPS.

Fuente: Elaboración propia.

Por último, se procede a realizar un centrado de los datos para el estado de Colima y después a descargar los datos en formato CSV para analizarlos con Python, en la Figura 12, se puede observar el código implementado.

```
// 4. Centrar el mapa en Colima y añadir capa
Map.setCenter(-104.0, 19.2, 7); // Coordenadas aproximadas de Colima
Map.addLayer(precipitation, precipitationVis, 'Precipitation Colima');
Map.addLayer(colima, {color: 'FF0000'}, 'Área de Colima'); // Opcional: para ver el bounding box

// Convertir ImageCollection a tabla (por día)
var tabla = precipitation.map(function(image) {
  var fecha = image.date().format('YYYY-MM-dd');
  var stats = image.reduceRegion({
    reducer: ee.Reducer.mean(),
    geometry: colima,
    scale: 5000
  });
  return ee.Feature(null, {
    'date': fecha,
    'precip_mm': stats.get('precipitation')
  });
});

// Exportar a CSV
Export.table.toDrive({
  collection: ee.FeatureCollection(tabla),
  description: 'CHIRPS_Colima_Oct2015_CSV',
  fileFormat: 'CSV'
});
```

Figura 12. Descarga de datos CHIRPS.

Fuente: Elaboración propia.

En la Figura 13 se ve una visualización de México con la precipitación de CHIRPS, con la fecha del mes de octubre del 2015, el color rojo es cuando existe mayor precipitación.




Figura 13. Mapa de precipitación CHIRPS de México.

Fuente: Elaboración propia.

## Análisis de los datos descargados con Python

En la Figura 14 se muestra el diagrama de flujo para el análisis de datos CHIRPS: filtrado espaciotemporal, cálculo de acumulados de lluvia y exportación a CSV para generar gráficas temporales en Python.




Figura 14. Diagrama de flujo para el procesamiento CHIRPS .

Fuente: Elaboración propia .

145

sión) por ausencia de datasets clasificados de referencia en la región. Sin embargo, se propone incorporar estas métricas en investigaciones futuras mediante el uso de datos de campo o incorporando sensores IoT para validación in situ y modelos híbridos (SAR + LSTM) para predicciones más robustas.

Modelos como U-Net o Random Forest fueron analizados en la revisión literaria, pero no fueron implementados en este estudio. Se plantean como posibilidad para investigaciones futuras.

En síntesis, este trabajo evidencia cómo la teledetección multidisciplinar —con tecnologías abiertas y gratuitas— puede transformar la respuesta ante desastres naturales, especialmente en regiones tropicales vulnerables como Colima. Los datos obtenidos no solo tienen valor académico, sino también aplicaciones concretas en políticas públicas de protección civil.

## BIBLIOGRAFÍA

[1] UNDRR. (2022). *Global assessment report on disaster risk reduction 2022*. <https://www.undrr.org> Recuperado el 4 de junio de 2025.

[2] WMO. (2021). *Atlas of mortality and economic losses from weather, climate and water extremes*. <https://library.wmo.int/> Recuperado el 4 de junio de 2025.

[3] Cajigal Molina, E., & Maldonado González, A. L. (2019). Metodología para el análisis de vulnerabilidad ante inundaciones. Un ejercicio emergente ante el cambio climático. *Economía, sociedad y territorio*, 19(61), 543–574.

[4] Rivera, J. A., Marianetti, G., & Scaglione, M. (2022). Análisis de los eventos de precipitación que afectan la distribución de agua potable en el Gran Mendoza, Argentina. *Cuadernos Geográficos*, 61(2), 204–222.

[5] Zavalegui, R. A. S., Alvarado, R. C., Rojas, M. A. B., Ruiz, M. M. C., & Sanabria, J. M. C. (2023). Vulnerabilidad social ante inundaciones pluviales en tres comunidades rurales mayas de Felipe Carrillo Puerto, Quintana Roo, México. *Sociedad y Ambiente*, (26), 1–32.

[6] Aguilar, J. P. M., & López, A. G. (2020). Daños económicos y sociales por huracanes e inundaciones en México: periodo de 2010 a 2015. *Aqua-LAC*, 12(2), 67–77.

[7] Velasco, I. A. (2023). Reseña de José Manuel Camacho Sanabria y Rosalía Chávez Alvarado, *Riesgos hidrometeorológicos en el sureste mexicano (Quintana Roo): inundaciones urbanas*. México: Universidad Autónoma del Estado de Quintana Roo, 2022. *Perspectiva Geográfica*, 28(2).

[8] González, O. M. (2021). El ciclón que nadie vio: Riesgos que potenciaron un desastre en el Noroeste de México. *Revista de Estudios Latinoamericanos sobre Reducción del Riesgo de Desastres REDER*, 5(1), 110–125.

[9] Ortiz, J. L. (2020). Vulnerabilidad en la ciudad costera: Modelo de prevención del riesgo hidrometeorológico. *Academia XXII*, 11(21), 3–20.

[10] CENAPRED. (2022). Resumen ejecutivo del impacto de desastres en México. <https://www.cenapred.unam.mx/es/Publicaciones/archivos/494-RESUMENEJECUTIVOIMPACTO2022.pdf> Recuperado el 4 de junio de 2025.

[11] European Space Agency (ESA). (2022). Sentinel-1: Radar observations.

[12] Pech-May, F., Aquino-Santos, R., & Delgadillo-Partida, J. (2023). Sentinel-1 SAR images and deep learning for water body mapping. *Remote Sensing*, 15(12), 3009. <https://doi.org/10.3390/rs15123009>.

[13] Tanim, A. H., McRae, C. B., Tavakol-Davani, H., & Goharian, E. (2022). Flood detection in urban areas using satellite imagery and machine learning. *Water*, 14(7), 1140. <https://doi.org/10.3390/w14071140>.

[14] Higuchi, A. (2021). Toward more integrated utilizations of geostationary satellite data for disaster management and risk mitigation. *Remote Sensing*, 13(8), 1553. <https://doi.org/10.3390/rs13081553>.

[15] Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Husak, G., Rowland, J., Harrison, L., Hoell, A., & Michaelsen, J. (2015). The climate hazards infrared precipitation with stations (CHIRPS) dataset for drought monitoring. *Scientific Data*, 2(1), 150066. <https://doi.org/10.1038/sdata.2015.66>.

[16] Giovannettone, J., Copenhaver, T., Burns, M., & Choquette, S. (2018). A statistical approach to mapping flood susceptibility in the Lower Connecticut River Valley region. *Water Resources Research*, 54(10), 7603–7618. <https://doi.org/10.1029/2018WR023018>.

[17] Kabir, S., Patidar, S., Xia, X., Liang, Q., Neal, J., & Pender, G. (2020b). A deep convolutional neural network model for rapid prediction of fluvial flood inundation. *Journal of Hydrology*, 590, 125481. <https://doi.org/10.1016/j.jhydrol.2020.125481>.

[18] Bentivoglio, R., Isufi, E., Jonkman, S. N., & Taormina, R. (2022). Deep learning methods for flood mapping: A review of existing applications and future research directions. *Hydrology and Earth*



System Sciences, 26(16), 4345–4378. <https://doi.org/10.5194/hess-26-4345-2022>.

[19] Tamiru Haile, A., Worku Bekele, T., & Rientjes, T. (2023). Interannual comparison of historical floods through flood detection using multi-temporal Sentinel-1 SAR images, Awash River Basin, Ethiopia. *International Journal of Applied Earth Observation and Geoinformation*, 124, 103505. <https://doi.org/10.1016/j.jag.2023.103505>.

[20] Wedajo, G. K., Lemma, T. D., Fufa, T., & Gamba, P. (2024). Integrating satellite images and machine learning for flood prediction and susceptibility mapping for the case of Amibara, Awash Basin, Ethiopia. *Remote Sensing*, 16(12). <https://doi.org/10.3390/rs16122163>.

[21] Roy, S., Bose, A., & Chowdhury, I. R. (2021a). Flood risk assessment using geospatial data and multi-criteria decision approach: a study from historically active flood-prone region of Himalayan foothill, India. *Arabian Journal of Geosciences*, 14(11), 999. <https://doi.org/10.1007/s12517-021-07324-8>.

[22] Nevo, S., Morin, E., Gerzi Rosenthal, A., Metzger, A., Barshai, C., Weitzner, D., Voloshin, D., Kratzert, F., Elidan, G., Dror, G., Begelman, G., Nearing, G., Shalev, G., Noga, H., Shavit, I., Yuklea, L., Royz, M., Giladi, N., Peled Levi, N., ... Matias, Y. (2022). Flood forecasting with machine learning models in an operational framework. *Hydrology and Earth System Sciences*, 26(15), 4013–4032. <https://doi.org/10.5194/hess-26-4013-2022>.

[23] Karim, F., Armin, M. A., Ahmedt-Aristizabal, D., Tychsen-Smith, L., & Petersson, L. (2023). A review of hydrodynamic and machine learning approaches for flood inundation modeling. *Water (Switzerland)*, 15(3). <https://doi.org/10.3390/w15030566>.

[24] Drakonakis, G. I., Tsagkatakis, G., Fotiadou, K., & Tsakalides, P. (2022). OmbriaNet-supervised flood mapping via convolutional neural networks using multitemporal Sentinel-1 and Sentinel-2 data fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 2341–2356. <https://doi.org/10.1109/JS-TARS.2022.3155559>.

[25] Tang, Y., Yan, M., Wang, X., Lu, C., & Luo, J. (2021). Experimental and modeling investigation of pumping from a fresh groundwater lens in an idealized strip island. *Journal of Hydrology*, 602, 126734. <https://doi.org/10.1016/j.jhydrol.2021.126734>.

[26] 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*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>.

[27] Twele, A., Cao, W., Plank, S., & Martinis, S. (2016). Sentinel-1-based flood mapping: A fully automated processing chain. *International Journal of Remote Sensing*, 37(13), 2990–3004. <https://doi.org/10.1080/01431161.2016.1192304>.

[28] Tarpanelli, A., Mondini, A. C., & Camici, S. (2022). Effectiveness of Sentinel-1 and Sentinel-2 for flood detection assessment in Europe. *Natural Hazards and Earth System Sciences*, 22, 2473–2489. <https://doi.org/10.5194/nhess-22-2473-2022>.

[29] Nouioua, T., Tarek, N. (2023). Flood Detection in Satellite Images using Deep Learning. In *Proceedings of the IEEE (via ResearchGate)*.

[30] Ghosh, B., Garg, S., Motagh, M., Martinis, S. (2024). Automatic Flood Detection from Sentinel-1 Data Using a Nested U-Net Model and a NASA Benchmark Dataset. *Earth Science Informatics*, 17(4).

