

# Hacia el mapeo, detección y prevención de incendios forestales mediante Machine Learning y datos hidrometeorológicos.

## Towards the mapping, detection and prevention of wildfires through Machine Learning and hydrometeorological data.

Lázaro Enrique Ehuan Jiménez (1).

Estudiante Tecnológico Nacional de México/Instituto Tecnológico Superior de los Ríos, Balancán, Tabasco.  
[lazaroenhji@gmail.com](mailto:lazaroenhji@gmail.com).

Jorge Magaña Govea (2). Instituto Tecnológico Superior de los Ríos, Balancán, Tabasco. [jorge.mg@rios.tecnm.mx](mailto:jorge.mg@rios.tecnm.mx).

Fernando Pech May\* (3), Instituto Tecnológico Superior de los Ríos, Balancán, Tabasco,  
[fernando.pech@cinvestav.mx](mailto:fernando.pech@cinvestav.mx).

Luis Antonio López Gómez (4), Instituto Tecnológico Superior de los Ríos, Balancán, Tabasco,  
[luis.lg@rios.tecnm.mx](mailto:luis.lg@rios.tecnm.mx).

Edna Mariel Mil Chontal (5), Instituto Tecnológico Superior de los Ríos, Balancán, Tabasco,  
[edna.mc@rios.tecnm.mx](mailto:edna.mc@rios.tecnm.mx).

\*corresponding author.

Artículo recibido en febrero 10, 2026; aceptado en junio 10, 2026.

### Resumen.

*Los incendios forestales representan un problema recurrente para ecosistemas y actividades agropecuarias en México, especialmente en la zona Ríos de Tabasco, donde la gestión preventiva se ve limitada por el uso poco sistemático de información ambiental. Este trabajo plantea como solución la integración operativa de información satelital, datasets hidrometeorológicos y herramientas de Sistemas de Información Geográfica (SIG) para construir series temporales de variables clave como LST, NDVI, precipitación, humedad del suelo, viento y cobertura terrestre. Con ello, se busca reducir el tiempo y la complejidad del análisis manual, sentando las bases para futuros modelos de machine learning que apoyen la detección temprana y la toma de decisiones en la gestión de incendios forestales.*

**Palabras claves:** Hidrometeorológicos, incendios forestales, LST, NDVI, series temporales.

### Abstract.

*The wildfires represent a recurring problem for ecosystems and agricultural activities in Mexico, especially in the Ríos region of Tabasco, where preventative management is limited by the unsystematic use of environmental information. This work proposes the operational integration of satellite information, hydrometeorological datasets, and Geographic Information System (GIS) tools to construct time series of key variables such as LST, NDVI, precipitation, soil moisture, wind, and land cover. This aims to reduce the time and complexity of manual analysis, laying the groundwork for future machine learning models that support early detection and decision-making in forest fire management.*

**Keywords:** Hydrometeorological, LST, NDVI, time series, wildfires.

## 1. Introducción.

Un incendio forestal es una fuerza de la naturaleza implacable y destructiva. A diferencia de un fuego controlado en una chimenea o una hoguera, se trata de una combustión sin control que se propaga rápidamente a través de la vegetación, transformando paisajes enteros en cuestión de horas (**Agrozapiens, s.f.**).

Los incendios forestales constituyen una de las amenazas ambientales más relevantes en México, tanto por los daños directos a ecosistemas forestales y agropecuarios como por sus impactos en la salud humana, la economía local y la estabilidad climática regional (**Comisión Nacional Forestal**).

Se estima que, cada año, se producen entre 60.000 y 80.000 incendios forestales que destruyen entre 3 y 10 millones de hectáreas de bosques. Algunas causas de estos incendios están asociadas a procesos naturales, no obstante, en la mayoría de los casos el fuego se origina por acciones humanas (**Juste, 2025**).

Además de la procedencia humana, la ocurrencia y propagación del fuego están condicionadas por factores ambientales que conforman la llamada gran tríada[3]. Dentro de las cuales destacan la temperatura, la velocidad y dirección del viento, la humedad del suelo, así como la duración de los periodos secos. El cambio climático intensifica estos factores al favorecer la desecación de la materia orgánica, lo que incrementa el potencial de ignición y la propagación de los incendios forestales (**Aquae, s.f.**).

Existen estudios relacionados a los incendios forestales, que hacen uso de imágenes satelitales y datos meteorológicos a lo largo de su desarrollo. Como el estudio realizado por la German Aerospace Center (DLR), en Alemania, tuvo como objetivo desarrollar un método de segmentación automática de áreas quemadas, usando imágenes de Sentinel-2 y redes neuronales convolucionales tipo U-Net (**Knopp, Wieland, Rättich, & Martinis, 2020**). De igual manera, el sistema descrito por la autora Prisha Shroff, que aporta una solución basada en la integración de Inteligencia Artificial y datos satelitales (NASA, NOAA) para una respuesta automatizada mediante drones (**Shroff, 2023**).

En este contexto, la existencia de instrumentos orientados a variables hidrometeorológicas y meteorológicas, combinados con plataformas de análisis como Google Earth Engine (GEE), permiten generar series temporales de alta frecuencia, facilitando el estudio de patrones espacio

En este trabajo se presenta un análisis integrado de datasets satelitales e hidrometeorológicos relacionados con las variables antes mencionadas. Aplicado para la gestión de incendios forestales en la zona Ríos del estado de Tabasco, con énfasis en el periodo 2015-2024. Para ayudar a sentar las bases de futuros usos en modelos de machine learning orientados en la gestión de incendios forestales.

### Marco Teórico.

La teledetección consiste en la adquisición de información de la superficie terrestre mediante sensores montados en plataformas aéreas o satelitales, utilizando principalmente la radiación del espectro electromagnético reflejada o emitida por los objetos en la superficie. Esta técnica permite obtener observaciones repetitivas a diferentes escalas espaciales y temporales, las cuales pueden integrarse en Sistemas de Información Geográfica (SIG) para el análisis y modelado de procesos ambientales (**Universidad de Alcalá, 2022**).

Los datos geoespaciales son información que describen objetos, eventos o fenómenos asociados a ubicaciones específicas sobre o cerca de la superficie terrestre, combinando la localización (por ejemplo, coordenadas), los atributos (características del fenómeno) y el momento o período en que ocurre, lo que permite analizar su comportamiento en el espacio y en el tiempo. Estos datos suelen representarse principalmente en dos formas: vectorial, mediante puntos, líneas y polígonos que describen entidades discretas (como edificios, carreteras o ríos), y raster, mediante celdas o

píxeles que representan fenómenos continuos o imágenes complejas, como fotografías aéreas o imágenes de satélite. Dado que, a menudo proceden de fuentes muy diversas y conforman grandes volúmenes de información, se integran habitualmente en Sistemas de Información Geográfica (SIG) y plataformas de análisis espacial, donde lenguajes como Python, ofrecen un entorno flexible y potente para su procesamiento y análisis (IBM, s.f.).

Existen distintos productos satelitales y de análisis para generar series temporales consistentes de variables climáticas y de superficie, que permiten el monitoreo global de procesos ambientales, la detección de cambios y el apoyo a la gestión de riesgos y recursos naturales. Estos instrumentos y conjuntos de datos producen datos geospaciales que combinan información espacial, temporal y temática, los cuales se integran en plataformas como Google Earth Engine para construir un conjunto coherente de factores hidrometeorológicos y de superficie en la zona de estudio.

En el caso de la temperatura de la superficie terrestre (LST), se utiliza el producto del sensor MODIS a bordo del satélite Terra, que ofrece estimaciones diarias de temperatura y emisividad de la superficie a 1 km de resolución; útil para estudios de monitoreo de extremos térmicos (NASA LP DAAC, 2025). La condición de la vegetación se caracteriza mediante el índice NDVI del producto CDR/VIIRS/NDVI/V1 (NOAA), desarrollado para disponer de una serie larga, continua y de alta calidad de NDVI global, propia para la detección de regiones afectadas por sequía (Vermote & Program, 2022).

La precipitación se incorpora a través del producto CHIRPS/DAILY, diseñado para generar un registro de lluvia cuasi global de alta resolución espacial y temporal, especialmente orientado al monitoreo de sequías y extremos de precipitación (Climate Hazards Center, 2025). La humedad del suelo se obtiene del producto SPL4SMGP/008 de la misión SMAP, creado para medir de forma sistemática la humedad del suelo, con el fin de mejorar la comprensión de los ciclos de agua, energía y carbono, así como la capacidad de pronosticar fenómenos como inundaciones y sequías (National Snow and Ice Data Center, 2025).

Las condiciones de viento se derivan del dataset ERA5/DAILY del ECMWF, un reanálisis global integrado para reconstruir la evolución del clima desde mediados del siglo XX; este producto proporciona los componentes u y v del viento a 10m, los cuales sirven para calcular la velocidad y dirección del viento, relevantes para la propagación de incendios y el transporte de humedad y calor (ECMWF, 2025). La estructura y dinámica de la cobertura terrestre se caracterizan mediante el producto MCD12Q1, un mapa global de cobertura del suelo a 500m de resolución espacial que proporciona una clasificación anual basada en los sensores MODIS Terra y Aqua; este producto ofrece distintos esquemas de clasificación, lo que permite representar de forma consistente los principales tipos de cobertura y uso del suelo a escala global (NASA LP DAAC, 2025).

## 2. Métodos.

Para el desarrollo de este proyecto, se hace uso de una metodología por etapas (ver **Figura 1**). Está comprendida por 5 etapas que se describen a continuación.

### 1. Definición del área de estudio.

El área de estudio corresponde a la denominada zona Ríos, ubicada en el estado de Tabasco, México, e integrada por los municipios de Balancán, Tenosique y Emiliano Zapata. Esta región se caracteriza por la presentación de ecosistemas forestales tropicales y áreas agropecuarias, con condiciones de alta vulnerabilidad frente a incendios forestales debido a la combinación de factores climáticos, uso del suelo y prácticas agrícolas.

Para el periodo 2015-2024, los registros oficiales de la Comisión Nacional Forestal (CONAFOR) reportan un total de 322 incendios forestales en el estado de Tabasco, de los cuales 47 se localizaron en la zona Ríos, representando alrededor del 14,6% del total estatal. La selección de esta región y del periodo de análisis se fundamentan en la disponibilidad de datos, la relevancia ecológica de los ecosistemas presentes y la recurrencia de eventos de incendio documentados.

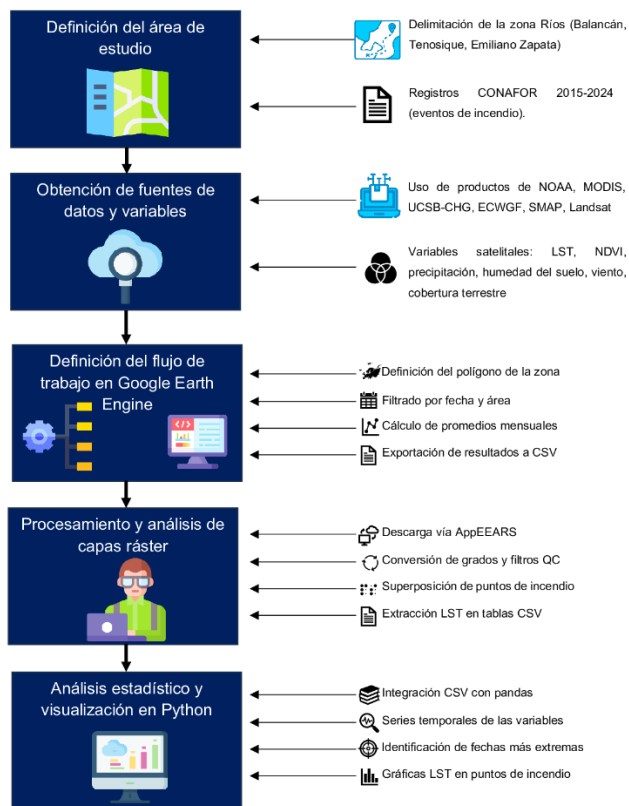


Figura 1. Diagrama de flujo de la metodología utilizada.

## 2. Obtención de fuentes de datos y variables.

La metodología integra dos grandes grupos de información: (i) registros de incendios forestales y (ii) datasets satelitales e hidrometeorológicos.

### Registro de incendios.

Se utilizaron los registros de incendios forestales de la CONAFOR, filtrados para el periodo 2015-2024 y delimitados a los municipios de la zona Ríos. Con el fin de hacer un análisis sobre el comportamiento de las variables definidas y mostrar como influyen en la posible ignición de estos incendios forestales.

### Variables satelitales e hidrometeorológicas.

Para caracterizar las condiciones ambientales asociadas a los incendios se seleccionaron los siguientes productos y bandas:

- Temperatura de la superficie terrestre (LST): producto MOD11A1, del sensor MODIS, con resolución espacial de 1 km y frecuencia diaria.
- Índice NDVI: producto CDR/VIIRS/NDVI/V1, del NOAA, con resolución global de 0.05° y disponibilidad desde 2014 en adelante.

- Precipitación: producto CHIRPS/DAILY, del UCSB-CHG, con resolución adecuada para análisis regional y cobertura casi en tiempo real.
  - Humedad del suelo: producto SPL4SMGP/008, del SMAP, que proporciona humedad del suelo superficial y de la zona radicular a escala global.
  - Velocidad y dirección del viento: dataset ERA5/DAILY, del ECMWF, usando los componentes **u** y **v** del viento a 10 m para derivar velocidad y dirección.
  - Cobertura terrestre: producto GLC\_FCS30D/annual, derivado de Landsat, que ofrece una clasificación anual de uso y cobertura del suelo a 30 m.
- La selección de estos productos satelitales obedece a criterios de actualidad, validación internacional, resolución y compatibilidad con flujos de trabajo automatizado en GEE y análisis posteriores en Python.

### 3. Definición del flujo de trabajo en Google Earth Engine

En GEE se definió un polígono de la zona Ríos mediante la carga de un shapefile, y se estableció el intervalo temporal 2015-2024. Para cada variable se desarrollaron scripts en JavaScript que realizan los siguientes pasos:

1. Filtrado de colecciones de imágenes por fecha y área de estudio.
  2. Cálculo de promedios mensuales para cada banda de interés (LST, NDVI, precipitación, humedad del suelo, velocidad y dirección del viento).
  3. Cálculo de estadísticas resumidas (media, mínimo, máximo) sobre el shapefile de la zona Ríos
  4. Exportación de los resultados a archivos CSV, incluyendo atributos temporales (año, mes) y espaciales (identificador de la región).
- Este flujo de trabajo permite construir series temporales mensuales de cada factor para la zona de estudio, facilitando el análisis conjunto y la comparación entre años.

### 4. Procesamiento y análisis de capas ráster.

QGIS se utilizó para el procesamiento detallado de capas ráster de LST descargadas desde AppEEARS y para la integración espacial de los puntos de incendio reportados por CONAFOR.

En el caso de la LST, los pasos fueron:

1. Descarga de productos MOD11A1 mediante AppEEARS, seleccionando las bandas LST\_Day1km, LST\_Night1km y las capas de control de calidad QCDay y QCNight, en formato GeoTIFF y proyección Geographic WGS84 (EPSG:4326).
2. Conversión de valores de temperatura de Kelvin a grados Celsius mediante la calculadora ráster en QGIS, aplicando la relación:  
$$T_{°C} = T_{LST} - 273,15 \dots \dots \dots \text{Ecuación 1.}$$
3. Aplicación de filtros por calidad utilizando las capas de control (QC) para excluir píxeles con baja confiabilidad.
4. Carga de archivo CSV con las coordenadas de los incendios, conversión a capas de puntos de superposición sobre las capas ráster de LST.
5. Extracción de valores de LST por punto y por fecha, generando capas temporales y tablas con la evolución de la temperatura en las ubicaciones de incendios durante su periodo de duración.  
Posteriormente, estas tablas serán exportadas en formato CSV para su análisis en Python, donde se generaron gráficas de series temporales que muestran el comportamiento de la temperatura antes, durante y después de cada evento.

### 5. Análisis estadístico y visualización en Python.

Los archivos CSV generados desde GEE y QGIS se procesaron en Python utilizando librerías como pandas, matplotlib y plotly, con el fin de:

- Construir series temporales de precipitación, humedad del suelo, LST, NDVI, viento y cobertura terrestre para el periodo 2015-2024.

- Comparar la variación mensual y anual de cada variable, identificando años y meses extremos.
- Analizar el comportamiento de las variables durante años con alta incidencia de incendios forestales, con énfasis en 2020.
- Visualizar la evolución de la temperatura en puntos específicos de incendios para comparar sus mediciones. Estas visualizaciones permiten identificar patrones comunes, como disminuciones de humedad del suelo y precipitación previas a periodos con mayor número de incendios, así como aumentos significativos en la LST coincidentes con los días de ocurrencia de los eventos.


### 3. Desarrollo.

Para realizar un análisis adecuado, se tiene definido obtener los valores durante el periodo 2015-2024 para la zona Ríos, en Tabasco, de las variables LST, NDVI, precipitación, humedad del suelo, velocidad y dirección del viento, y cobertura terrestre. Esto basándose en registros de incendios forestales dados por la CONAFOR. Se describe el comportamiento de los valores a lo largo del periodo y en el año con mayor presencia de estos eventos (2020).


A continuación, se muestran el comportamiento de estas variables mediante gráficas obtenidas utilizando GEE.

#### Distribución espacial y temporal de los incendios.

El análisis de los registros de CONAFOR para el periodo 2015-2024 indica que la zona Ríos concentró 47 incendios forestales, lo que equivale a cerca del 14,6% de los eventos registrados en Tabasco. La distribución revela años con mayor recurrencia, destacando 2020 como el año con el mayor número de incendios en la región como se muestra en la **Figura 2**, con un total de 15 eventos, así como 2024, que registra un incendio de gran extensión en el municipio de Tenosique con 1901,33 ha afectadas.



**Figura 2.** Eventos de incendio durante el periodo 2015-2024, zona Ríos, Tabasco.




**Figura 3.** Comportamiento de variables específicas, año 2020.

Como se puede observar en la **Figura 3**, una vez obtenidos los valores de las variables de LST, NDVI, Humedad del suelo y Precipitación dentro del periodo mencionado, se puede observar que existe una convergencia en su comportamiento durante el mes de marzo del 2020 de todas las variables, pero el LST en contraste, se encuentra en su pico máximo en ese punto. Dando como resultado, que los comportamientos llegan a tener un punto que corrobora que estas variables se relacionan al posible origen de incendios forestales. La ubicación de los focos de incendios sobre capas de temperatura y cobertura terrestre muestra que muchos de estos eventos se concentran en zonas de uso agropecuario y pastizales, donde las prácticas de quema para preparación de siembra son frecuentes, y en áreas con vegetación que puede acumular material combustible durante los periodos secos.


### Temperatura de la superficie terrestre (LST).

Las series temporales derivadas de MOD11A1, (ver **Figura 4**) muestran que, durante los días de ocurrencia de los incendios analizados, se observan incrementos pronunciados de la temperatura superficial. Estos incrementos se manifiestan como picos en las gráficas de LST, lo que sugiere que esta variable puede servir como indicador robusto de anomalías térmicas asociadas a la presencia de fuego.



**Figura 4.** Picos máximos LST, 2015-2024.


En análisis detallados de eventos específicos (ver **Figura 5**), la extracción de LST diaria en las coordenadas de incendios permite comparar el comportamiento térmico antes, durante y después del evento, evidenciando una señal térmica bien definida durante los días de mayor actividad del incendio. Este tipo de comportamiento refuerza la utilidad de la LST como variable clave para la detección y seguimiento de incendios.



**Figura 5.** Picos máximos LST, año 2020.


### Índice NDVI y vegetación.

Las series NDVI generadas para la zona Ríos entre 2015 y 2024 muestran una marcada estacionalidad, con valores más altos en periodos húmedos y descensos durante la época seca. Para el año 2020, que presenta el mayor número de incendios, los valores de NDVI se sitúan alrededor de 0,5 en ciertos periodos como se observa en la **Figura 6**, lo cual es consistente con áreas de cultivos o praderas, donde la biomasa disponible puede actuar como combustible en condiciones de baja humedad.



**Figura 6.** Picos máximos en el índice NDVI, 2015-2024.


En la escala de un evento específico (ver **Figura 7**), al analizar la evolución del NDVI antes y después de un incendio, se aprecia una reducción en los valores del índice, lo que refleja la pérdida de vegetación y daños en la cobertura vegetal. Esta información es especialmente útil para la evaluación de impactos y la identificación de zonas que requieren acciones de restauración.



**Figura 7.** Picos máximos en el índice NDVI, año 2020.

**Precipitación y humedad del suelo.**

Las gráficas de precipitación mensual basadas en CHIRPS para la zona Ríos mostradas en la **Figura 8**, mantienen una variabilidad interanual significativa, con meses extremadamente húmedos y otros con acumulados bajos, particularmente en años con alta incidencia de incendios. Para 2020, por ejemplo, se registran periodos con acumulados inferiores a los umbrales considerados como moderados, lo que coincide con una mayor susceptibilidad a incendios.



**Figura 8.** Variabilidad de la precipitación, 2015-2024.

La humedad del suelo derivada de SMAP como se muestra en la **Figura 9**, revela que los periodos de mayor ocurrencia de incendios tienden a coincidir con condiciones de humedad baja o seca-moderada en los meses previos, lo que indica que la disminución de la humedad en el perfil superficial favorece la disponibilidad de combustible fino seco. Estas

observaciones sugieren que la combinación de precipitación deficitaria y humedad del suelo reducida puede ser un precursor importante de escenarios de alto riesgo.




Figura 9. Comportamiento en la humedad del suelo, 2015-2024.

**Velocidad y dirección del viento.**

El análisis de la velocidad y dirección del viento a partir de ERA5 (ver Figura 10) muestra que, en la zona Ríos, predominan vientos de intensidades bajas a moderadas, con episodios específicos de ráfagas más fuertes que pueden influir en la propagación de incendios. Las series temporales indican que ciertos eventos de incendio se desarrollan en días donde la velocidad del viento aumenta respecto al promedio, lo que potencialmente contribuye a la expansión del frente de fuego.




Figura 10. Comportamiento en la velocidad y dirección del viento, 2015-2020.

**Cobertura terrestre.**

La clasificación de uso y cobertura del suelo a partir del producto MCD12Q1 muestra que, en la zona Ríos, la mayor proporción de la superficie está cubierta por bosques de hoja ancha, mosaicos de vegetación natural y cultivos de temporal, con una presencia menor de áreas urbanas y vegetación escasa o suelo desnudo. La distribución porcentual de las clases revela que las tierras agrícolas y los mosaicos natural-cultivo ocupan una fracción significativa de la región como se observa en la Figura 11, lo cual coincide con el contexto de incendios asociados a prácticas agrícolas.




Figura 11. Distribución de la cobertura terrestre, 2015-2020.

Una vez obtenidos los valores de cada variable durante el periodo y área definido, se evalúa un incendio particular de gran extensión ocurrido entre el 22 de mayo y el 10 de junio de 2024, como se observa en la Figura 12, el cruce de la variabilidad en NDVI con la velocidad del viento sugiere que la presencia de vegetación susceptible, combinada con periodos de viento superior a la brisa ligera, pudo favorecer la propagación del incendio a lo largo del paisaje.




Figura 12. Comparación de variables NDVI y de viento durante un evento específico.

### Conclusiones.

Al llevar a cabo el análisis integrado de datasets hidrometeorológicos y de imágenes satelitales para la zona Ríos de Tabasco, que permite apoyar a asentar las bases para futuros modelos de machine learning que apoyen la detección temprana y la toma de decisiones en la gestión de incendios forestales, permite concluir que la combinación de las variables como LST, NDVI, precipitación, humedad del suelo, velocidad y dirección del viento y cobertura terrestre ofrece un marco robusto para la caracterización de las condiciones que favorecen la ocurrencia y propagación de incendios forestales. La frecuencia de observación y la amplia cobertura espacial de sensores como MODIS, complementando con productos como CHIRPS, SMAP y ERA5, hacen posibles detectar anomalías térmicas y cambios en la vegetación casi en tiempo real.

Los resultados indican que los años con mayor incidencia de incendios, como 2020, se asocian a periodos de baja precipitación, reducción en la humedad del suelo y valores de NDVI compatibles con cultivos y pastizales, lo que incrementa la disponibilidad de combustible seco. Asimismo, la superposición de focos de incendio con mapas de cobertura terrestre evidencia la importancia de las zonas agrícolas y de mosaico natural-cultivo como áreas críticas para la gestión del riesgo.

Finalmente, se recomienda profundizar en las siguientes líneas de trabajo: (i) ampliar el conjunto de variables predictoras incorporando información socioeconómica y de uso del suelo más detallada; (ii) validar los modelos con datos independientes y campañas de campo; y (iii) explorar la transferencia de modelos entrenados en la zona Ríos hacia otras regiones con condiciones climáticas y de vegetación similares, evaluando su generalización y utilidad para la gestión integral de incendios forestales a escala regional y nacional.

A partir de la integración de estos datasets, se establece una base sólida para el desarrollo de modelos de machine learning orientados tanto a la prevención como a la detección temprana de incendios, en línea con las experiencias internacionales que han mostrado altas precisiones mediante el uso de Random Forest, regresión logística y redes neuronales convolucionales. La adopción de tales enfoques puede contribuir de manera sustantiva a mejorar los sistemas de alerta temprana, optimizar la planificación de brigadas y apoyar la toma de decisiones en materia de protección ambiental y manejo del territorio.

### Referencias bibliográficas.

**Agrozapiens. (s.f.).** *¿Qué es un incendio forestal y qué lo causa?* Obtenido de Agrozapiens: <https://agrozapiens.com/que-es-un-incendio-forestal-y-que-lo-causa/>

**Aquae. (s.f.).** *Causas y efectos de los incendios forestales.* Obtenido de Aquae: <https://www.fundacionaquae.org/como-luchar-contra-incendios-forestales/>

**Climate Hazards Center. (2025).** *CHIRPS Precipitation Daily: Climate Hazards Center InfraRed Precipitation With Station Data (Version 2.0 Final).* Universidad de California, Santa Bárbara. Obtenido de [https://developers.google.com/earth-engine/datasets/catalog/UCSB-CHG\\_CHIRPS\\_DAILY](https://developers.google.com/earth-engine/datasets/catalog/UCSB-CHG_CHIRPS_DAILY)

**Comisión Nacional Forestal. (s.f.).** *236Guía práctica para comunicadores - Incendios Forestales.* Obtenido de CONAFOR: <http://www.conafor.gob.mx:8080/documentos/docs/10/236Gu%c3%ada%20pr%c3%a1ctica%20para%20comunicadores%20-%20Incendios%20Forestales.pdf>

**ECMWF. (2025).** *ECMWF Reanalysis v5.* European Centre for Medium-Range Weather Forecasts. Obtenido de <https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5>

**IBM. (s.f.).** *¿Qué son los datos geospaciales?* Obtenido de IBM: <https://www.ibm.com/mx-es/think/topics/geospatial-data>

**Juste, I. (3 de Marzo de 2025).** *Consecuencias de los incendios forestales.* Obtenido de Ecología Verde: <https://ecologiaverde.elperiodico.com/consecuencias-de-los-incendios-forestales-234.html>

**Knopp, L., Wieland, M., Rättich, & Martinis, S. (2020).** A Deep Learning Approach for Burned Area Segmentation with Sentinel-2 Data. *Remote Sensing*, 12(15), 1-22. Obtenido de <https://doi.org/10.3390/rs12152422>

**NASA LP DAAC. (2025).** *MCD12Q1.061 MODIS Land Cover Type Yearly Global 500m SIN Grid.* NASA EOSDIS Land Processes DAAC. Obtenido de <https://doi.org/10.5067/MODIS/MCD12Q1.061>

**NASA LP DAAC. (2025).** *MODIS/Terra Land Surface Temperature/Emissivity Daily L3 Global 1km SIN Grid V061 (MOD11A1).* NASA EOSDIS Land Processes DAAC. Obtenido de <https://doi.org/10.5067/MODIS/MOD11A1.061>

**National Snow and Ice Data Center. (2025).** *SMAP L4 Global 3-hourly 9 km EASE-Grid Surface and Root Zone Soil Moisture Geophysical Data, Version 8.* National Snow and Ice Data Center. Obtenido de <https://doi.org/10.5067/T5RUATAQREF8>

**Shroff, P. (2023).** AI-based Wildfire Prevention, Detection and Suppression System. *arXiv*, 1-6. Obtenido de <https://doi.org/10.48550/arXiv.2312.06990>

**Universidad de Alcalá. (2022).** *Teledetección Ambiental - Environmental Remote Sensing.* Obtenido de uah.es:

<https://www.uah.es/es/investigacion/unidades-de-investigacion/grupos-de-investigacion/Teledeteccion-Ambiental-Environmental-Remote-Sensing/#Coordinador>

**Vermote, E., & Program, N. C. (2022).** *NOAA Climate Data Record (CDR) of VIIRS Normalized Difference Vegetation Index (NDVI), Version 1.* NOAA National Centers for Environmental Information. Obtenido de <https://doi.org/10.25921/gakh-st76>

### Información de los autores.



**Lázaro Enrique Ehuan Jiménez**, Estudiante de Ingeniería en Sistemas Computacionales, del Instituto Tecnológico Superior de los Ríos.



**Jorge Magaña Govea**, es Profesor investigador del Instituto Tecnológico Superior de los Ríos. Maestro en Ciencias de la Computación por la UJAT. Actualmente es miembro del Cuerpo Académico de Cómputo Distribuido, Perfil PRODEP y miembro del Sistema Estatal de Investigadores del estado de Tabasco. Sus áreas de interés son la ingeniería de Software, ontologías y web semántica. Ha impartido cursos orientados a la implementación de metodologías ágiles de desarrollo de software y formulación de proyectos.



**Fernando Pech May**, es Profesor investigador del Instituto Tecnológico Superior de los Ríos (ITSR). Realizó sus estudios de maestría en el Centro de Investigación y Estudios Avanzados del IPN (CINVESTAV) en el área de Inteligencia Artificial. Se especializó en Web Semántica en la Universidad de Chile. Finalizó su doctorado en Ciencias de la Computación en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET). Líder del cuerpo académico Cómputo Distribuido del ITSR, miembro activo de la Sociedad Mexicana de Inteligencia Artificial y la Asociación Mexicana para el Procesamiento de Lenguaje Natural. Sus áreas de interés son Deep Learning, Web Semántica y PLN.



**Luis Antonio López Gómez**, es Profesor del Instituto Tecnológico Superior de los Ríos en el área de Computación. Imparte docencia de Programación Web, Redes, en la carrera de Ingeniería en Sistemas Computacionales. Su labor de investigación se centra en las líneas de Inteligencia Artificial y Sistemas Distribuidos. Es Ingeniero en Sistemas Computacionales. Cuenta con 15 años de experiencia. Es miembro del cuerpo académico computo distribuido. Asimismo, acredita numerosas contribuciones a congresos y participaciones el desarrollo de proyectos de investigación de PRODEP y TecNM. Ha publicado más de 10 artículos nacionales e internacionales, artículos indexados en revistas de prestigio en los últimos años. Ha dirigido Tesis de Licenciatura. Actualmente es miembro del Sistema Estatal de Investigadores. Imparte talleres sobre Diseño de Apps Móviles, Uso de Látex en trabajos académicos y Consejos para la elaboración de trabajos académicos



**Edna Mariel Mil Chontal**, es Maestra en Ciencias en la Computación por el Centro de Investigación y de estudios avanzados del IPN, campus Tamaulipas. Es Licenciada en Computación por la Universidad Autónoma de Tabasco. Profesora del Instituto Tecnológico Superior de los Ríos y pertenece al cuerpo Académico “Cómputo Distribuido”. Sus áreas de interés son: Sistemas Distribuidos, Procesamiento de Lenguaje Natural y Redes de Próxima Generación.