

# Hacia la detección de inundaciones mediante imágenes satelitales y redes neuronales convolucionales.

## Towards flood detection using satellite images and convolutional neural networks.

José de Jesús Rodríguez Ángel.  
Tecnológico Nacional de México, Campus de los Ríos.  
[josergzdev@gmail.com](mailto:josergzdev@gmail.com).

Fernando Pech May\*. Tecnológico Nacional de México, Campus de los Ríos, [fernando.pech@cinvestav.mx](mailto:fernando.pech@cinvestav.mx).

---

\*corresponding author.

Artículo recibido en septiembre 30, 2022; aceptado en diciembre 16, 2022.

### Resumen.

*Los desastres naturales son fenómenos que ocurren a nivel mundial, estos son inevitables y, a menudo, ocasionan grandes daños. Sin embargo, es posible proponer estrategias para mejorar la capacidad de respuesta frente a ellos y mitigar las afectaciones producidas por este tipo de fenómenos. En México, las inundaciones son la catástrofe que ocurre con mayor frecuencia, ocasionando afectaciones en distintos sectores; tales como la agricultura, ganadería y en la economía. Esto ha ocasionado que se busquen estrategias para reducir el impacto producido en las poblaciones. En los últimos años se han realizado diversas investigaciones relacionadas con la detección de inundaciones. La mayoría de estos estudios utilizan imágenes satelitales y algoritmos de aprendizaje profundo para lograr mapear zonas inundadas. La combinación de estas tecnologías se está convirtiendo en uno de los métodos más efectivos. En este trabajo se presenta una propuesta metodológica para la detección de inundaciones en la zona Ríos del Estado de Tabasco, mediante imágenes satelitales Sentinel-1 SAR, Sentinel-2 y algoritmos de aprendizaje profundo.*

**Palabras claves:** Aprendizaje profundo, Sentinel-1, Sentinel-2.

### Abstract.

*Natural disasters are phenomena that occur worldwide, are inevitable and often cause great damage. However, it is possible to propose strategies to improve the capacity to respond to them and mitigate the effects produced by this type of phenomena. In Mexico, floods are the most frequently occurring catastrophe, affecting different sectors such as agriculture, livestock and the economy. This has led to the search for strategies to reduce the impact on the population. In recent years, several research studies have been carried out related to flood detection. Most of these studies use satellite images and deep learning algorithms to map flooded areas. The combination of these technologies is becoming one of the most effective methods. In this paper we present a methodological proposal for the detection of floods in the Ríos area of the state of Tabasco, using Sentinel-1 SAR, Sentinel-2 satellite images and deep learning algorithms.*

**Keywords:** Deep learning, Sentinel-1, Sentinel-2.

## 1. Introducción.

Los desastres naturales son fenómenos que causan grandes estragos a nivel mundial. Estadísticamente, las inundaciones se generan con mayor frecuencia, ocasionando un gran número de pérdidas materiales y humanas (Vargas, 2002).

En México, se han presentado diversas inundaciones que han ocasionado severas afectaciones. Entre las más graves resaltan las ocurridas en el estado de Tabasco en los años 2007 y 2020; provocando que un gran porcentaje de su extensión territorial haya quedado completamente cubierta por agua. Esto generó afectaciones en distintos sectores, tales como el agrícola, la ganadería y la infraestructura (Perevochtchikova, 2010).

Particularmente, la zona de los Ríos del estado de Tabasco siempre resulta severamente afectada. Esto es debido a la gran cantidad de ríos y cuerpos de agua que posee, entre ellos el río Usumacinta, el más caudaloso del país, y el río San Pedro. En consecuencia, lo hace una región muy propensa a inundarse, principalmente, por el desbordamiento de los ríos que se encuentran en esta zona.

Frente a estas problemáticas, se buscan desarrollar distintas estrategias que sirvan para reducir considerablemente los daños causados por este tipo de fenómenos. Dar solución a esta problemática, ayudaría a las autoridades competentes, ya que permitiría deducir de una mejor manera los alcances de la situación de emergencia, con lo que se podría determinar un mejor plan de acción (Di Bella et al., 2008). Para lograr este objetivo se hace uso de distintas herramientas y tecnologías, que trabajando conjuntamente logran dar resultados favorables. Recientes investigaciones han demostrado que mediante imágenes satelitales y algoritmos de aprendizaje profundo (DL), es posible mapear y detectar inundaciones (Bai et al., 2021; Katiyar et al., 2021; Nemni et al., 2020; Drakonakis et al., 2022; Ngo et al., 2018).

En este trabajo se presenta una estrategia para la detección de zonas inundadas, haciendo uso de imágenes satelitales Sentinel-1 SAR y Sentinel-2 junto con algoritmos de aprendizaje profundo. El presente documento está estructurado de la siguiente manera: en la sección 2 el marco teórico; en la sección 3 los trabajos relacionados; en la sección 4 la metodología propuesta y el desarrollo de esta; en la sección 5 los resultados obtenidos y en la sección 6 las conclusiones.

## 2. Métodos.

Recientemente las investigaciones se han centrado en el estudio de imágenes satelitales obtenidas a través de la percepción remota (PR) (Zerda, 2005). La PR se realiza a través de sensores remotos, los cuales son sistemas capaces de captar y registrar información territorial a distancia. Existen dos tipos de sensores (Di Bella et al., 2008): 1) pasivos, que capturan la energía electromagnética proveniente del sol y la reflejada sobre la superficie terrestre y 2) activos, que no necesitan al sol como fuente de energía electromagnética ya que estos generan su propia energía.

En los últimos años se han puesto en marcha distintos programas de monitoreo satelital, uno de ellos es Copernicus, coordinado por la Agencia Espacial Europea (ESA) juntamente con otras organizaciones. Esta misión tiene como finalidad brindar información basada en datos satelitales de la Tierra.

ESA ha desarrollado y puesto en marcha una serie de misiones llamadas SENTINEL destinadas al monitoreo ambiental. Proporciona un conjunto de datos de forma gratuita. Sentinel ofrece distintos satélites artificiales: 1) Sentinel-1, para estudiar la superficie de la tierra y los océanos; 2) Sentinel-2, para monitorizar la superficie de la tierra estudiando la cubierta vegetal, los usos del terreno y de las aguas; 3) Sentinel-3, para servicios de pronóstico marítimo y de la monitorización del clima y del medio ambiente; 4) Sentinel-4, para monitoreo de la atmósfera de nuestro planeta desde una órbita polar y 5) Sentinel-5, para estudio de la atmósfera. En el caso particular de la detección de inundaciones, se trabaja comúnmente con los satélites Sentinel 1 y 2.

Sentinel-1 proporciona imágenes de tipo rada (SAR, radar de apertura sintética). Tiene la ventaja de poder capturar imágenes diurnas y nocturnas sin importar las condiciones meteorológicas; es capaz de brindar información para servicios terrestres y oceánicos. Por otra parte, Sentinel-2 proporciona imágenes ópticas de una alta resolución, es capaz de brindar imágenes de la vegetación, suelo y coberturas de agua, como lo son las vías de navegación o las zonas costeras (Copernicus, 2020). Mediante la captura de este tipo de imágenes podemos obtener una gran cantidad de información.

Distintas investigaciones mencionan a la inteligencia artificial (IA), con la que es posible obtener resultados favorables en materia de detección de inundaciones, para esto debemos entender que la inteligencia artificial es una tecnología que está siendo utilizada cada vez más y que se puede encontrar en otras áreas, lo que la IA busca es dotar a las máquinas de la capacidad para utilizar algoritmos, para que aprendan datos de ellos y posteriormente puedan utilizar lo aprendido en la toma de decisiones, como si fuera un ser humano (Rouhiainen, 2018). Una de las áreas de la inteligencia artificial con mayor auge es la del aprendizaje automático (ML), incorporada en utilidades como la detección de spam, recomendaciones de videos o la clasificación de imágenes (Alzubaidi et al., 2021). Entre los distintos algoritmos de ML, el aprendizaje profundo (DL) es uno de los más utilizados. DL está diseñado con una estructura que utiliza distintas capas de algoritmos (RNA, redes neuronales artificiales) y que posee la ventaja de lograr la extracción de características de una manera automática, por lo que es un modelo muy atractivo para todo tipo de investigaciones.

Las RNA se inspiran en el sistema nervioso y el comportamiento biológico, tratando de replicar su funcionamiento, se basan en un sistema de interconexiones entre capas (Alzubaidi et al., 2021); las redes más utilizadas son: redes neuronales recursivas, recurrentes y convolucionales. Las redes neuronales convolucionales (CNN), nacen de la necesidad de poder procesar imágenes, este tipo de red es capaz de descifrar patrones complejos, cuneta con una capa de entrada, una o varias capas de convolución y una capa de salida, es famosa ya que con ella podemos ser capaces de encontrar patrones en imágenes para reconocer objetos, caras y escenas. A raíz de esto se ha demostrado la efectividad de utilizar métodos de aprendizaje profundo, basados en redes neuronales convolucionales, en la evaluación de daños por inundaciones (Bai et al., 2021).

### **Trabajos relacionados.**

Debido a que las inundaciones son muy frecuentes en distintas poblaciones del mundo, se han realizado esfuerzos para el desarrollo de diversas estrategias con la finalidad de mitigar los daños ocasionados por estos fenómenos. Debido a esto, se han realizado diferentes propuestas de investigación para la detección y mapeo de inundaciones. Dichas propuestas presentan enfoques, que se basan fundamentalmente en el uso de imágenes satelitales y algoritmos de DL, principalmente CNN (Bai et al., 2021; Katiyar et al., 2021; Nemni et al., 2020; Drakonakis et al., 2022; Ngo et al., 2018).

En (Bai et al., 2021) propusieron un enfoque para la detección de inundaciones basado en la fusión de datos mediante imágenes de Sentinel-1 SAR y Sentinel-2. Ellos utilizaron el *dataset* Sen1Floods11 (Bonafilia et al., 2020), que contiene aproximadamente 4831 imágenes Sentinel 1 y 2. Estas imágenes corresponden a eventos de inundaciones que han ocurrido en el mundo. Dividieron el *dataset* en tres partes: entrenamiento, validación y pruebas. Para lograr la fusión de estos datos, adaptaron el remuestreo de resolución espacial y la normalización del valor del píxel. Posteriormente utilizaron una arquitectura de red neuronal convolucional llamada BASNet (Qin et al., 2019). Esta red se aplicó al conjunto de datos para el entrenamiento y optimización para una mejor predicción en la detección de áreas de inundación. La robustez del algoritmo se verificó en inundaciones en Bolivia. Finalmente, se validó el modelo, en donde se aplicaron cinco métricas de evaluación: Intersección sobre Unión (IoU), Intersección media sobre Unión (mIoU), precisión general, tasas de error por omisión y tasas de error de comisión. Los resultados mostraron que el método propuesto en el estudio es superior comparado con otros modelos clásicos.

En (Katiyar et al., 2021) presentaron un estudio dedicado al mapeo de inundaciones, basado en modelos de aprendizaje profundo e imágenes satelitales de tipos SAR. Utilizaron el *dataset* público Sen1Floods11. Este *dataset* se dividió en dos partes: 1) datos de eventos de inundaciones y 2) datos de cuerpos de agua permanentes. El área de estudio para la aplicación del modelo fue en el estado de Kerala, en el sur de la India. La arquitectura de red que se utilizó, fueron

variantes de codificadores automáticos, redes tipo SegNet (Badrinarayanan et al., 2017) y UNet (Ronneberger et al., 2015). Las métricas de validación que utilizaron fueron las siguientes: IoU; error de omisión y comisión. Finalmente, concluyeron en la utilidad que las imágenes SAR representan para la detección de aguas superficiales y que los modelos pueden tener mejoras adicionales, siempre y cuando se entrenen con mejores conjuntos de datos.

En (Nemni et al., 2020) presentaron una comparativa de diferentes arquitecturas de redes neuronales utilizadas para el mapeo de inundaciones. Para su enfoque utilizaron un *dataset* de inundaciones, llamado UNOSAT (UNOSAT, 2019); que contiene imágenes satelitales de Sentinel-1 y fueron adquiridas en *Copernicus Open Access Hub*. Dividieron su conjunto de datos en tres secciones: entrenamiento, validación y pruebas. Compararon el rendimiento de distintas CNN utilizando este *dataset*. Por último, se verificó el modelo y se probó su rendimiento en la región de Sagaing, Myanmar. Su modelo fue evaluado con dos métricas: IoU y puntajes F1. Finalmente, mostraron el rendimiento de las distintas redes y evaluaron sus resultados.

En (Drakonakis et al., 2022) propusieron una arquitectura enfocada en el estudio de predicción de inundaciones, la cual está basada en CNN. Esta arquitectura fue nombrada OmbriaNet y es capaz de detectar los cambios entre las áreas de agua permanente e inundaciones. Para lograrlo desarrollaron su propio *dataset* denominado OMBRIA. Para validar el rendimiento de su método, utilizaron las dos métricas más populares para la segmentación: IoU y precisión de píxeles. Al finalizar demostraron que el modelo propuesto fue capaz de generar mapas de inundaciones de alta calidad.

En (Ngo et al., 2018) presentaron una investigación, en la que se presenta una nueva metodología para la detección de inundaciones, utilizando imágenes de Sentinel-1 SAR y una técnica híbrida de aprendizaje profundo. La zona de estudio es el área de Bac Ha Bao Yen (BHBV), ubicado en la región noroeste de Vietnam. Crearon una base de datos utilizando datos del Sistema de Información Geográfica (SIG), posteriormente entrenaron el modelo con la información de su base de datos. Para finalizar, validaron su modelo a través de distintas métricas de rendimiento, incluida la tasa de precisión de clasificación, el área bajo la curva, la precisión y la recuperación. Como resultado, su modelo fue comparado con otras redes y la predicción del modelo propuesto es mejor. Por lo tanto, se puede concluir que la metodología propuesta es una herramienta muy prometedora para la detección de inundaciones.

### **Propuesta metodológica.**

La inteligencia artificial junto con las imágenes satelitales, se han convertido en herramientas importantes para el mapeo y detección de inundaciones. Diversos estudios manejan diferentes metodologías para conseguir este objetivo. A continuación, se presenta una propuesta de enfoque (ver Figura 1) para la detección de inundaciones mediante imágenes satelitales Sentinel y algoritmos de aprendizaje profundo. El enfoque consta de 5 etapas que se describen a continuación.

#### **Datos de entrada.**


La zona de estudio es la zona Ríos del estado de Tabasco (ver Figura 2). En este enfoque se propone la utilización de una CNN para lograr el mapeo y detección de inundaciones, por lo tanto, se requieren datos de entrada, los cuales alimentarán a la red para lograr su objetivo. Por esta razón, nuestros datos de entrada serán imágenes satelitales de nuestra área de estudio, con las que se construirá un conjunto de datos que sirva como datos de entrada para todo el modelo metodológico.

#### **Preprocesamiento de imágenes.**


Las imágenes que se adquieren requieren ser procesadas. Dado que se manejarán 2 tipos de imágenes, el procesamiento se realiza de distinta manera. Este proceso es importante debido a la aplicación de distintas correcciones a la imagen, lo que nos da como resultado imágenes corregidas y óptimas para posteriormente utilizarlas en la CNN.

**Modelo de aprendizaje profundo.**

Las CNN son un tipo de red neuronal que, debido a su funcionamiento interno, son muy efectivas para tareas de visión artificial, principalmente, la clasificación y segmentación de imágenes. Por lo tanto, este tipo de red neuronal resulta efectiva para ser utilizada en el proceso de detección de inundaciones.



**Figura 1.** Metodología empleada para la detección de inundaciones.



**Figura 2.** Zona Ríos del estado de Tabasco.

En esta propuesta de enfoque se utilizará un algoritmo de aprendizaje profundo para poder lograr el mapeo y la detección de inundaciones. Se utilizará una red neuronal convolucional. La red propuesta se llama U-Net, se eligió

utilizar este tipo de arquitectura, debido a sus ventajas de comparación a otras redes existentes para la segmentación de imágenes. La red propuesta, está diseñada para ser eficiente tanto en términos de memoria como en tiempo computacional durante la inferencia. Otra ventaja determinante a la hora de seleccionar la arquitectura a utilizar fue el número de parámetros entrañables, en donde U-Net tiene números significativamente menores, con todo esto, esta red proporciona un buen rendimiento con un tiempo de inferencia competitivo y una memoria de inferencia más eficiente.

### Evaluación y resultados.

Un proceso importante al trabajar con algoritmos de aprendizaje profundo como las redes neuronales convolucionales, es la etapa de validación; ya que se aplican diferentes algoritmos para medir el rendimiento y la efectividad del modelo. Para este proceso se adoptaron tres indicadores para medir el desempeño del enfoque, se optó por utilizar estos indicadores ya que se consideran las métricas estándar para la segmentación semántica.

**Precisión.** Esta métrica es un punto de control para evaluar la precisión de un modelo, ya que nos permite medir la calidad del modelo en tareas de clasificación (Heras, 2020). Se calcula haciendo uso de la Formula 1 que se muestra a continuación

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

**Recall.** Esta es una métrica que nos informa sobre la cantidad que nuestro modelo es capaz de identificar. Se calcula como la relación entre el número de muestras positivas clasificadas correctamente como positivas y el número total de muestras positivas (Heras, 2020). Esta métrica de evaluación mide la capacidad del modelo para detectar muestras positivas, lo que significa que cuanto mayor sea el *recall*, más muestras positivas habrá detectadas.

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

**F1.** Esta métrica de evaluación se utiliza para combinar las medidas de precisión y *recall* en un solo valor. Esto es practico porque hace más fácil del poder comparar el rendimiento combinado de la precisión y el *recall* (Heras, 2020). El valor F1 se calcula haciendo una media entre la precisión y la exhaustividad.

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (3)$$

## 3. Resultados.

Hasta el momento los resultados son parciales y se está trabajando en la parte 2 y 3 de la metodología.

### Obtención de imágenes.

Para el mapeo de inundaciones y la implementación de la CNN es necesario tener una buena cantidad de datos de entrada, para esto se necesitan obtener imágenes satelitales del área de estudio. Estas imágenes fueron obtenidas de la plataforma gratuita *Copernicus Open Acces Hub* (ver Figura 3).

### Preprocesamiento.

**Calibración radiométrica.** Este tipo de corrección es el primer paso en el preprocesamiento de las imágenes, esto se hace para disponer de los valores de retrodispersión de los píxeles. Lo que permite corregir distorsiones de la señal de rada, es un primer paso para la interpretación y visualización de las imágenes.

**Filtro *speckle*.** Este filtro permite suavizar la imagen, debido a la naturaleza de las imágenes SAR estas tienen un efecto de sal y pimienta, de ser utilizada la imagen sin aplicar este filtro, se pueden tener dificultades y resultados erróneos a la hora de implementar la CNN.

**Corrección geométrica.** Originalmente las imágenes pueden ser obtenidas con alguna distorsión espacial, incluso pueden estar rotadas, debido a las orbitas y manera de captura por parte del satélite, lo que hace que nuestros elementos se encuentren deformados. Para la aplicación de cada uno de los filtros y las correcciones a las imágenes se utilizó el software SNAP.

### Creación de puntos de muestra.

Antes de implementar nuestro modelo de aprendizaje profundo, es necesario construir muestras de entrenamiento. Para este proceso se carga nuestra imagen corregida al software SIG (Sistema de Información Geográfica) llamado ArcGis Pro, que nos permite generar estas muestras de entrenamiento. Se crea una clase llamada inundación y se van etiquetando las áreas de la imagen en la que se sabe que es una zona inundada, esto se hace dibujando polígonos manualmente en las imágenes (ver Figura 4).



Figura 3. Imagen satelital del área de estudio.

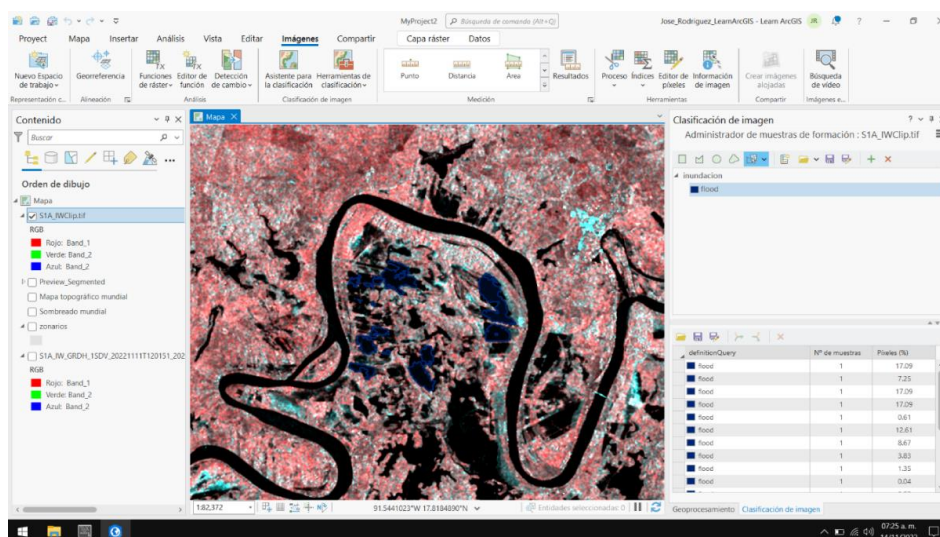


Figura 4. Etiquetas de entrenamiento

## Conclusiones.

Debido a que las inundaciones causan una gran cantidad de estragos, ha surgido la necesidad de implementar nuevas estrategias para mitigar los daños ocasionados por este tipo de fenómenos. Actualmente, existen tecnologías y herramientas como la PR y IA, que, trabajando conjuntamente, se pueden usar para proponer soluciones ante este tipo de problemáticas.

Las misiones satelitales y los repositorios de imágenes de este tipo son muy importantes a la hora del estudio de inundaciones, ya que de ellas se extrae una gran cantidad de información y son utilizadas, ya que de ellas se extrae una gran cantidad de información y son utilizadas en los algoritmos de DL. Dentro de estos algoritmos las redes neuronales convolucionales son las encargadas de procesar todas las imágenes y juegan un papel fundamental en el proceso de mejora de la clasificación de inundaciones.

## Referencias bibliográficas.

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L. (2021).** Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 1-74.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017).** Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- Bai, Y., Wu, W., Yang, Z., Yu, J., Zhao, B., Liu, X., ... & Koshimura, S. (2021).** Enhancement of detecting permanent water and temporary water in flood disasters by fusing sentinel-1 and sentinel-2 imagery using deep learning algorithms: Demonstration of sen1floods11 benchmark datasets. *Remote Sensing*, 13(11), 2220.
- Bonafilia, D., Tellman, B., Anderson, T., & Issenberg, E. (2020).** Sen1Floods11: A georeferenced dataset to train and test deep learning flood algorithms for sentinel-1. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 210-211).
- Copernicus. (2020).** *Estos son nuestros satélites*. Recuperado el 17 de diciembre de 2022, de <https://www.copernicus.eu/es/sobre-copernicus/infraestructura/estos-son-nuestros-satelites>.
- Di Bella, C. M., Posse, G., Beget, M. E., Fischer, M. D. L. A., Mari, N., & Veron, S. (2008).** La teledetección como herramienta para la prevención, seguimiento y evaluación de incendios e inundaciones. *Ecosistemas*, 17(3).
- 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.
- Heras, J. M. (2020).** *Precision, Recall, F1, Accuracy en clasificación*. IArtificial.net. <https://www.iartificial.net/precision-recall-f1-accuracy-en-clasificacion/>.
- Katiyar, V., Tamkuan, N., & Nagai, M. (2021).** Near-real-time flood mapping using off-the-shelf models with SAR imagery and deep learning. *Remote Sensing*, 13(12), 2334.
- Nemni, E., Bullock, J., Belabbes, S., & Bromley, L. (2020).** Fully convolutional neural network for rapid flood segmentation in synthetic aperture radar imagery. *Remote Sensing*, 12(16), 2532.
- Ngo, P. T. T., Hoang, N. D., Pradhan, B., Nguyen, Q. K., Tran, X. T., Nguyen, Q. M., ... & Tien Bui, D. (2018).** A novel hybrid swarm optimized multilayer neural network for spatial prediction of flash floods in tropical areas using sentinel-1 SAR imagery and geospatial data. *Sensors*, 18(11), 3704.



- Perevochtchikova, M., & de la Torre, J. L. L. (2010).** Causas de un desastre: Inundaciones del 2007 en Tabasco, México. *Journal of Latin American Geography*, 73-98.
- Qin, X., Zhang, Z., Huang, C., Gao, C., Dehghan, M., & Jagersand, M. (2019).** Basnet: Boundary-aware salient object detection. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 7479-7489).
- Ronneberger, O., Fischer, P., & Brox, T. (2015).** U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- Rouhiainen, L. (2018).** Inteligencia artificial. *Madrid: Alienta Editorial*.
- UNOSAT Flood Portal. (2019).** Unosat.org. Recuperado el 18 de diciembre de 2022, de <http://floods.unosat.org/geoportal/catalog/main/home.page>
- Vargas González, J. E. (2002).** Políticas públicas para la reducción de la vulnerabilidad frente a los desastres naturales y socio-naturales.
- Zerda, H. (2005).** Percepción remota y SIG en la planificación y gestión ambiental. *G. y. Ludueña, Santiago del Estero: una mirada ambiental*, 333-354.

### Información de los autores.



**José de Jesús Rodríguez Ángel**, Estudiante de Ingeniería en Sistemas Computacionales en el Instituto Tecnológico Superior de los Ríos, llevando a cabo residencia profesional, con el proyecto denominado “Revisión y propuesta de enfoques para la detección de inundaciones mediante imágenes Sentinel-1, Sentinel-2 y aprendizaje profundo”.



**Fernando Pech May** es Ingeniero en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Valle de Bravo, Estado de México, cuenta con Maestría en Ingeniería en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Ecatepec. Tiene la distinción de Perfil Deseable ante PRODEP y es miembro del cuerpo académico en formación “procesamiento de datos con industria 4.0” del Tecnológico de Estudios Superiores de Valle de Bravo.