

Revisión sistemática de la literatura sobre técnicas de inteligencia artificial en la predicción de desastres naturales**Systematic review of the literature on artificial intelligence techniques in the prediction of natural disasters.**

Yuly Lilibeth Macías Mero, Mgs. David Fernando Zambrano Montenegro, Ing. Ángelo Steeven Macías Mero.

**CONFLUENCIA DE
INNOVACIONES CIENTÍFICAS**

Enero - junio, V°5-N°1; 2024

- ✓ **Recibido:** 20/06/2024
- ✓ **Aceptado:** 30/06/2024
- ✓ **Publicado:** 30/06/2024

PAIS

- Ecuador - Portoviejo
- Ecuador - Portoviejo
- Ecuador - Portoviejo

INSTITUCIÓN:

- Universidad Técnica de Manabí
- Universidad Técnica de Manabí
- Universidad Técnica de Manabí

CORREO:

- ✉ ymacias7678@utm.edu.ec
- ✉ david.zambrano@utm.edu.ec
- ✉ amacias7686@utm.edu.ec

ORCID:

- 🌐 <https://orcid.org/0009-0001-3039-8430>
- 🌐 <https://orcid.org/0000-0002-8833-1546>
- 🌐 <https://orcid.org/0009-0000-5503-4468>

FORMATO DE CITA APA

Macías, Y. Zambrano, D. Macías, A. (2024). *Revisión sistemática de la literatura sobre técnicas de inteligencia artificial en la predicción de desastres naturales*. Revista G-ner@ndo, V°5 (N°1), 1205 – 1235.

Resumen

Los desastres naturales son las consecuencias de fenómenos que atentan contra el medio ambiente, las personas y sus bienes; la inmersión tecnológica en este campo posibilita mitigar estas consecuencias a través de técnicas de predicción. En la presente revisión se analiza sistemáticamente la literatura sobre técnicas de inteligencia artificial para predecir estos incidentes, teniendo como prioridad identificar tendencias en el uso de técnicas y la precisión de sus algoritmos. Este trabajo sigue el marco PRISMA, se realizaron búsquedas en las bases de datos: Scopus, ACM e IEEE y con uso de la herramienta Parsifal se incluyeron 28 estudios para la revisión. Los resultados se presentan en tres áreas: Desastres naturales sujetos a predicción mediante técnicas de IA, técnicas de IA utilizadas y la precisión de los modelos/algoritmos utilizados, se evidencia que las inundaciones son el desastre natural más estudiado con un 72,73 % dentro de la literatura analizada, como técnica más empleada resalta el Aprendizaje automático con un 46,43% y dentro de los modelos/algoritmos sobresalen: los Bosques Aleatorios como el de uso más recurrente y el modelo ANFIS en conjunto a los algoritmos GOA y GWO como el de mayor precisión, entre 97,5% y 94,4%. Lo expuesto deja como evidencia que las técnicas de inteligencia artificial tienen el potencial de mejorar la predicción de desastres naturales, pero es importante presentar variaciones técnicas para garantizar que la implementación de estos obtenga mejores resultados, como el uso de modelos híbridos y datos fiables, completos y actualizados.

Palabras claves. Desastres naturales, fenómenos naturales, Inteligencia Artificial, Técnicas de IA, Predicción.

Abstract

Natural disasters are the consequences of phenomena that threaten the environment, people and their property; technological immersion in this field makes it possible to mitigate these consequences through prediction techniques. This review systematically analyzes the literature on artificial intelligence techniques to predict these incidents, with the aim of to predict these incidents, having as a priority to identify trends in the use of techniques and the accuracy of their algorithms. This work follows the PRISMA framework, searches were performed in the following databases: Scopus, ACM and IEEE, and 28 studies were included in the review using the Parsifal tool. The results are presented in three areas: natural disasters subject to prediction using AI techniques, AI techniques used and the accuracy of the models/algorithms used, it is evident that floods are the most studied natural disaster with 72.73 % within the analyzed literature, as the most used technique stands out Machine Learning with 46.43% and within the models/algorithms stand out: Random Forests as the most recurrent use and the ANFIS model together with the GOA and GWO algorithms as the one with the highest accuracy, between 97.5% and 94.4%. The above shows that artificial intelligence techniques have the potential to improve the prediction of natural disasters, but it is important to present technical variations to ensure that the implementation of these techniques obtains better results, such as the use of hybrid models and reliable, complete and updated data.

Keywords. Natural disasters, Natural phenomena, Artificial Intelligence, AI techniques, Prediction

Introducción

Los desastres naturales, son fenómenos impredecibles causados generalmente por agentes ajenos al control humano. Estos eventos atentan contra el medio ambiente, la vida de las personas y sus pertenencias; según la Agencia Europea de Medio Ambiente (EEA), las olas de calor cobran alrededor de 16.000 vidas en Europa, convirtiéndolo en el continente con la tasa de mortalidad más alta por agentes naturales. De manera similar, Asia es la región con mayor impacto sufrido a raíz de los desastres naturales en general, Pakistán se vio afectado por inundaciones que causaron aproximadamente 15 mil millones de dólares en daños (Filali Bouami, 2005). Esto indica la importancia de mitigar el alto impacto prediciendo estos desastres y elaborando planes de contingencia.

El creciente factor de riesgo ha estimulado la exploración y utilización de enfoques de inteligencia artificial (IA) como una de las medidas para la predicción de estos fenómenos, destacando su potencial para minimizar los efectos en la economía global y la calidad de vida humana. Las técnicas usadas por y para la IA surgen como instrumentos eficaces con múltiples enfoques, sin embargo, a pesar de su capacidad, estas no están exentas de los desafíos tanto técnicos y éticos, principalmente el sesgo en la entrada de los datos y la privacidad de los mismo, que deben ser abordados de forma que se asegure la implementación equitativa y efectiva de esta tecnología (Banafa, 2023). Con base en esto, se infiere que la aplicación de la inteligencia artificial debe cumplir ciertos parámetros para lograr resultados veraces, caso contrario, se crearán falsos positivos en el resultado de las predicciones; por lo tanto, es necesario revisar las investigaciones existentes sobre la temática.

La existencia de trabajos que examinen el estado del conocimiento sobre la predicción de los desastres a través de técnicas de inteligencia artificial es limitada. En (Khan et al., 2020) se abordan únicamente estudios sobre las inundaciones, evaluando tres modelos de obtención de datos que usan Inteligencia Artificial para la predicción y el monitoreo de este tipo de desastres. Además de ser muy específico, la cantidad de estudios revisados es relativamente

reducida (18), por lo que se considera oportuno ampliar el estudio con una pertinente actualización de las revisiones (2010-2020). En contraparte, en (Arinta & Andi W.R., 2019) se realiza una revisión extensa que incluye 70 trabajos comprendidos en el periodo 2014-2019, este enfoca los desastres naturales sin distinción, sin embargo, categoriza la aplicación de técnicas de IA en 6 áreas de gestión de desastres, de los cuales solo 10 trabajos se asocian al área de previsión o predicción.

Por su parte, el presente estudio tiene como objetivo principal realizar una revisión sistemática de la literatura sobre las técnicas de inteligencia artificial usadas para la predicción de desastres naturales, tenido como enfoque central determinar tendencias sobre las técnicas y algoritmos de IA, en conjunto a su precisión, empleadas en este campo. Mediante una evaluación minuciosa de estudios científicos contemporáneos se identificaron los desastres naturales evaluados, las técnicas utilizadas y la precisión de sus algoritmos. De esta forma se podrá comprender el estado actual del conocimiento en este tópico y marcar pautas de acuerdo a la eficacia de estas predicciones, colaborando así para una mejor respuesta ante emergencias.

El presente artículo está estructurado en cuatro secciones adicionales de la siguiente forma: la Sección 2 es el estado del arte donde se abordan los conceptos que brinden contexto teórico (Inteligencia artificial y desastres naturales) y se presentan trabajos relacionados a la temática; la Sección 3 describe la metodología empleada para el desarrollo de la investigación; la Sección 4 presenta los resultados (análisis de los datos y discusión de los mismos); y finalmente, la Sección 5 expone las conclusiones que responden a manera de síntesis las interrogantes científicas del trabajo.

Los desastres naturales son la consecuencia de fenómenos naturales, estos acontecimientos traen consigo pérdidas de vidas humanas y de recursos económicos, generalmente en una relación proporcional a la magnitud del fenómeno. Esto afecta sustancialmente al desarrollo de los países, ya que el ámbito socio-económico suele tener los

mayores estragos. Ante esto, se genera una preocupación en aumento para mitigar los daños que se puedan producir (San Martín Neira, 2019).

La Inteligencia Artificial es la capacidad que poseen los equipos de cómputo para aprender datos y usar algoritmos, y con base a esto tomar decisiones como lo haría un ser humano. No obstante, las máquinas no necesitan descanso y su volumen de procesamiento en paralelo es mucho mayor. De la misma manera, el margen de error en los dispositivos basados en IA es considerablemente menor, siempre que los datos de entrada sean los pertinentes (Rouhiainen, 2018).

- Aprendizaje Automático (Machine Learning): Proceso que permite adquirir inteligencia automáticamente, sin haber sido programados específicamente para una tarea concreta (Montañés Salas & Hoyo Alonso, 2019).
 - Aprendizaje Profundo (Deep Learning): Se usa la capacidad de abstracción jerárquica, en otras palabras, representa los datos de entrada en varios “niveles”, una característica de un nivel alto de complejidad será aprendido de una de un nivel de complejidad menor (Restrepo Arteaga, 2015).
 - Procesamiento del Lenguaje Natural (NLP): Es la habilidad de la máquina para procesar la información comunicada, no simplemente las letras o los sonidos del lenguaje (Gelbukh, 2010).
 - Visión por Computadora: Tiene como objetivo modelar y automatizar el proceso de reconocimiento visual, es decir, distinguir entre objetos e identificar diferencias en base a las características de lo captado (Alonso & Jara, 2016).
 - Aprendizaje por Refuerzo (Reinforcement Learning): El ambiente suministra datos y los agentes reaccionan a estos y actúan de acuerdo a los objetivos, estos son recompensados de acuerdo a las acciones tomadas según el estado del ambiente (Latorre, 2019). En el trabajo de Bhowmik et al. (Bhowmik et al., 2023), se destaca la importancia de utilizar algoritmos de aprendizaje automático y sistemas expertos en clima para predecir eventos meteorológicos críticos. En este
-

se emplean datos históricos de incendios forestales, información ambiental y una red neuronal avanzada para predecir y anticipar incendios de gran magnitud, destacando la importancia de predicciones precisas para salvar vidas y proteger el medio ambiente.

En la misma línea, el modelo de aprendizaje profundo FireXnet, diseñado por Ahmad et al. (Ahmad et al., 2023), fue propuesto para detectar incendios forestales, su eficiencia radica en el bajo consumo de recursos, agilizando el entrenamiento y prueba. Emplea SHAP para interpretar sus decisiones, y sobresale respecto a otros con una precisión del 98,42%. Esta integración garantiza precisión y transparencia al identificar claves para la detección de incendios, reduciendo la complejidad computacional y los tiempos de proceso. Otras investigaciones, se enfocan en mitigar las inundaciones con base en el nivel de los ríos, haciendo uso de la inteligencia artificial y datos históricos del nivel del agua, estacionalidad, y los fenómenos; Moreno (Moreno Castillo, 2019) en su propuesta destaca a las Redes Neuronales Artificiales, que en cuanto a precisión fue la de mejores resultados. Además, no solo se ofrece precisión, sino también la capacidad de interpretar las condiciones desencadenantes de las inundaciones.

Por otra parte, en China (Saad et al., 2023), se han realizado múltiples pruebas con información recopilada mediante sensores, el objetivo es predecir la ubicación y magnitud terremotos, teniendo como resultado, una prueba que logra una exactitud del 70%. Si bien se menciona que la predicción de terremotos es uno de los desafíos más grandes para la IA, estudios revelan que con el apoyo de análisis de componentes principales, aprendizaje automático supervisado y Big Data es cada vez más posible.

Métodos y materiales

La metodología aplicada para este estudio está basada en PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), que en conjunto de la herramienta Parsifal nos permitieron realizar la planificación, el desarrollo y redacción del

trabajo investigativo (Ilustración 1).




Ilustración 1: *Esquema de revisión*

En primer lugar, se hizo uso del método de búsqueda PICOC para definir nuestras palabras claves (tabla 1).

Tabla 1:

Palabras clave

<i>Término</i>	<i>Keyword</i>
<i>Población</i>	<i>Desastres Naturales, Fenómenos Naturales</i>
<i>Intervención</i>	<i>Inteligencia Artificial, Técnicas de IA</i>
<i>Resultado</i>	<i>Pronosticar</i>

Con estos términos se elaboró la cadena de búsqueda: **("Natural Disasters" OR "Catastrophes" OR "Natural Phenomena") AND ("AI" OR "Artificial Intelligence" OR "AI Techniques") AND ("Prediction" OR "Detection")**.

Y de la misma forma se han definido las preguntas de investigación (QR), enumeradas a continuación:

- ¿Cuáles desastres naturales se han abordado con mayor frecuencia en los estudios de predicción mediante inteligencia artificial?
- ¿Qué técnicas de inteligencia artificial son usadas en la predicción de desastres naturales?
- ¿Cuál es la precisión de los algoritmos/modelos de IA para predecir eventos catastróficos?

Lo criterios de inclusión y exclusión mostrados en la Tabla 2, han sido considerados de esta forma: se incluyen trabajos que respondan al menos una de las preguntas de investigación, artículos de revistas indexados, un periodo de publicación no mayor a 6 años desde la actualidad y como idioma de publicación el inglés. Por su parte, se excluyen artículos con aplicaciones ajenas al tema, capítulos de libros y reviews por la posible falta de revisión, documentos de conferencia por la no culminación de las propuestas, y los artículos duplicados.

Tabla 2:

Criterios de inclusión y exclusión

<i>Criterios de inclusión</i>	<i>Criterios de exclusión</i>
<i>Artículos de revistas indexadas</i> <i>Periodo de publicación: 2018-2024</i> <i>Idioma: inglés</i>	<i>Capítulos de libros.</i>
	<i>Conferencias sin resultados.</i>
	<i>Documentos deslindados al tema de investigación.</i>
	<i>Duplicados.</i>
	<i>Reviews.</i>

En complemento, y con afán de determinar la suficiencia de los artículos elegidos, se ha planteado preguntas de evaluación de la calidad de los trabajos.

- ¿Se trabaja con todas las variables incluidas en la investigación?
- ¿El estudio presenta limitaciones y posibles sesgos asociados con la aplicación de la inteligencia artificial?

- ¿Se evalúa la precisión de la técnica de IA en predicciones (se hacen pruebas de la eficiencia y robustez)?


Considerando aptos los artículos que cumplan el umbral de al menos 2pts en esta evaluación, teniendo la puntuación:

- SI: 1,0
- PARCIAL: 0,5
- NO: 0,0

Para la revisión se ha usado dos bases de datos, las subjetivamente, de mejor valoración en el ámbito investigativo: Scopus, Biblioteca Digital ACM y Biblioteca digital IEEE. En donde además de introducir la cadena de búsqueda, se delimitó el año de publicación, y con los resultados se hizo la selección considerando los criterios de inclusión y exclusión, así como la puntuación obtenida con base en las preguntas que evalúan la calidad.


En la ilustración 2 se detalla el proceso de selección de acuerdo al método PRISMA, categorizado en tres fases: la identificación, el cribado y la inclusión final. En el apartado de identificación, se detallan los registros iniciales y se realiza la revisión de duplicados; en el cribado, se examinan y recuperan los trabajos potenciales, que posteriormente son descartados de acuerdo a los parámetros pertinentes (criterios de exclusión, temas desvinculados y poca calidad de acuerdo a la evaluación de la misma). Finalmente, se obtiene el número de registros o trabajos elegidos para la presente investigación.

Ilustración 2: Flujo de proceso de selección PRISMA 2020



Resumen de los trabajos de la revisión

En la ilustración 3 se expone la relación entre los trabajos arrojados por la búsqueda inicial en las tres fuentes escogidas denotando que Scopus tiene la mejor relación entre la búsqueda inicial y la inclusión final.

Ilustración 3: *Relación de aceptación por fuentes*

De manera similar, de acuerdo al año de la publicación (Ilustración 4), se nota apogeo entre los años 2020 y 2023, que de acuerdo a (Catástrofes naturales globales 2010-2022 | Statista, s. f.) son años con gran tendencia a desastres naturales.

Ilustración 4: *Publicaciones por año*

En cuanto a los países que más aportes hacen a este tema de investigación (Ilustración 5); India, Pakistán, Malasia y EEUU son los países con mayor frecuencia, de los cuales 3 son países de Asia, la región con mayor susceptibles a los fenómenos y/o desastres naturales.

Ilustración 5:

Numero de publicaciones de acuerdo al país

**Análisis de resultados**

Con base en el formulario para la extracción de datos, presentado en la sección 3, se han segmentado las variables que contribuyen a las preguntas de investigación, en esta sección se presentan los resultados tabulados; se resumen las técnicas, la precisión de los algoritmos, y los desastres naturales en los que son aplicadas para predecir su incidencia. Se encuentra cierta variedad en los desastres naturales estudiados por los trabajos identificados (Tabla 3). Se destaca que el desastre que más impacto genera en el estudio de técnicas de IA para la predicción son las inundaciones, seguido y con menos frecuencia se encuentran los incendios forestales; a partir de aquí se identifican desastres con menor asiduidad tales como; los terremotos, deslizamientos de tierra, sequías, lluvias torrenciales y los huracanes.

Tabla 3: Desastres identificados en los estudios.ID	Desastre	Descripción	Referencia
D1	Inundaciones	Es la elevación del agua sobre la altura tradicional del cauce (Jason, 2015).	(Khan et al., 2019), (Chen et al., 2022), (Hashi et al., 2021), (Yaseen et al., 2022), (Ahmed et al., 2022), (Moishin et al., 2021), (Sahoo et al., 2021), (Defontaine et al., 2023), (Khalaf et al., 2020), (Moreno et al., 2023), (Bhargavi & Suma, 2020), (Zulkifli et al., 2022), (Aswad et al., 2022), (Peng et al., 2019), (Jain et al., 2020), (Sanubari et al., 2018)
D2	Terremotos	Se dan de manera repentina en áreas de terrenos causando severos daños, es uno de los fenómenos más temidos (Bolt, 2022).	(Tehseen et al., 2021), (Zainab et al., 2023)
D3	Sequía	Impacta la provisión de recursos hídricos necesarios para el desarrollo y la vida humana (Marcos Valiente, 2001).	(Kaur & Sood, 2020)
D4	Incendios forestales	Son fuegos inmensos descontrolados y destructivos (Pausas, 2020).	(Tzimas et al., 2023), (Abdollahi & Pradhan, 2023), (Sathishkumar et al., 2023), (Ntinopoulos et al., 2023), (Moreno et al., 2023)
D5	Deslizamientos de tierra	La tierra se desplaza rápidamente creando canales en el suelo (Murillo Gutiérrez et al., 1991).	(Tran-Anh et al., 2022), (Kavzoglu et al., 2021)
D6	Lluvias torrenciales	Son lluvias que superan la intensidad promedio provocando riesgos climáticos (Tamayo Carmona & Núñez Mora, 2020).	(Ria et al., 2021)
D7	Huracanes	Son las tormentas más grandes y violentas en la Tierra (Arjona et al., 2017).	(Kim & Hasegawa, 2018)

Como se puede observar son 7 los desastres naturales estudiados en la revisión realizada, dentro de estos, el desastre más recurrente son las inundaciones con un 72,73 %, los incendios forestales se posicionan con un 22,73% de recurrencia, luego aparecen los terremotos y los deslizamientos de tierra, ambos con un 9,02% de reincidencia y finalmente las sequías, las lluvias torrenciales y los huracanes con un 4,55% que indica un trabajo incluido con cada uno de estos.

Según (Méndez Garabetti, 2022) los Incendios Forestales son de los fenómenos naturales más frecuentes y alarmantes, considerando que este estudio se enfoca en América, tomando como muestra EE.UU y Argentina, lo que hace que los resultados de su estudio difieran a los de la presente investigación, misma que no posee delimitación geográfica, lo que da como resultado que los desastres naturales que más interés generan en los autores son las inundaciones, que ocurren y generan preocupación mayormente en regiones asiáticas, además de que la predicción de este tipo de desastre tiende a ser más precisa por la cantidad de datos que dan indicios de su probabilidad (*¿Cómo Se Predice Las Inundaciones?*, 2024). En la tabla 4, se exponen las técnicas de mayor uso por parte de los autores incluidos en esta revisión. Entre estos, se destacan, el aprendizaje automático (ML), el aprendizaje profundo (DL) y las redes neuronales artificiales (ANN) como las empleadas con mayor frecuencia. Dejando notar que la técnica de ML posee mayor madurez y ventaja frente a las demás técnicas como lo podemos notar en la tabla 4 gracias a que es la que mayormente se emplea para la predicción de desastres naturales.

Tabla 4:

Técnicas empleadas en la predicción de desastres naturales

ID	Técnica	Descripción	Referencia
T1	Aprendizaje automático	Genera algoritmos que tienen la capacidad de aprender y no tener que programarlos de	(Khan et al., 2019), (Yaseen et al., 2022), (Sahoo et al., 2021), (Abdollahi & Pradhan, 2023),

		manera explícita (Sandoval Serrano, 2018).	(Defontaine et al., 2023), (Khalaf et al., 2020), (Zainab et al., 2023), (Moreno et al., 2023), (Supriya & Gadekallu, 2023), (Bhargavi & Suma, 2020), (Ria et al., 2021), (Aswad et al., 2022), (Peng et al., 2019)
T2	Aprendizaje profundo	Usa algoritmos que representan los datos en niveles de abstracción (Restrepo Arteaga, 2015).	(Chen et al., 2022), (Hashi et al., 2021), (Moishin et al., 2021), (Tran-Anh et al., 2022), (Kavzoglu et al., 2021)
T3	Aprendizaje federado	Entrena modelos de redes neuronales profundas utilizando datos distribuidos (Gahete Morillo, 2023).	(Tehseen et al., 2021)
T4	Red neuronal artificial	Es un sistema que permite establecer una relación entre entradas y salidas inspiradas en el sistema nervioso (Narvaez, 2017).	(Kaur & Sood, 2020), (Ahmed et al., 2022), (Ntinopoulos et al., 2023), (Sanubari et al., 2018), (Kim & Hasegawa, 2018)
T5	Red neuronal profunda	Tienen un mayor número de capas de neuronas entre ellos que se conectan unas con otras (Herrera Delgado, 2021).	(Tzimas et al., 2023)
T6	Red neuronal convolucional	Tipo de red neuronal multicapa inspirada en el sistema visual de los seres vivos (Ghosh et al., 2020).	(Sathishkumar et al., 2023), (Jain et al., 2020)
T7	Red neuronal no lineal	Es una red neuronal que utiliza transformaciones no lineales en sus capas (Linkedin, s. f.).	(Zulkifli et al., 2022)

En total, se identificaron 7 técnicas de inteligencia artificial entre la selección de estudios para predecir desastres naturales, Entre estas desatacan: Aprendizaje automático, la más

frecuente con un 46,43% de recurrencia entre la literatura analizada, del mismo modo, el aprendizaje profundo y las redes neuronales artificiales son también técnicas que tienen un empleo significativo, ambas empleadas en el 17.86% de los estudios. Existen 4 técnicas resultantes con un índice de uso menor; estas son, las redes neuronales convolucionales con 7,14%, y con 3,57% cada una, el aprendizaje federado, las redes neuronales profundas y las no lineales.

Varios estudios adicionales coinciden en que el aprendizaje automático es la técnica mayormente empleada para la predicción. Tal como se lo menciona en (Aracena et al., 2022), el aprendizaje automático posee varios algoritmos, esto denota la variedad de aplicación respaldada por su eficiencia; ya que a la hora de predecir, los resultados más precisos teóricamente, se obtienen mediante el aprendizaje automático (*¿Qué es la IA predictiva?*, s. f.), lo que hace del ML un fuerte postulante para usar en modelos predictivos basados en IA. Ante lo mencionado recientemente y los hallazgos de la revisión bibliográfica del presente trabajo, se fortalece que el ML sea la técnica más frecuente en implementación.

Para determinar qué tan eficiente puede la implementación de un algoritmo de IA en modelos predictivos es necesario que estos tengan pruebas que evalúen la precisión de sus predicciones. En la Tabla 5 se muestran 38 Modelos/Algoritmos junto a su respectiva descripción y precisión, resultados de la recopilación en la que 26 de los estudios seleccionados aportan en esta pregunta de investigación. De tal manera se evidencia que los más comunes en implementación son: Bosques aleatorios, Memoria a Corto y Largo Plazo, Redes Neuronales Artificiales y Árbol de decisión; siendo el primero de estos el que ha obtenido mejores resultados en la precisión.

Tabla 5: *Precisión de los modelos y algoritmos aplicados*

ID	Modelo/Algoritmo	Descripción	Precisión	Referencia
----	------------------	-------------	-----------	------------

A1	SVM (Máquinas de Vectores de Soporte)	Son un algoritmo que mejora el clasificador lineal buscando un mejor hiperplano que el que se genera con el clasificador lineal (Benítez et al., 2014).	97,4%	(Khan et al., 2019)
A2	RF (Bosques aleatorios)	Combina la salida de varios árboles de decisiones para alcanzar un resultado único (Botana, s. f.).	98,7%	(Hashi et al., 2021)
			99%	(Yaseen et al., 2022)
			81,13%	(Khalaf et al., 2020)
			91,8%	(Bhargavi & Suma, 2020)
			87,68%	(Ria et al., 2021)
A3	K-NN (k-Vecinos Más Cercanos)	Guarda en memoria los ejemplos durante el proceso de entrenamiento y la clasificación de nuevos ejemplos se basa en las clases de los k ejemplos más cercanos (Benítez et al., 2014).	86,57%	(Aswad et al., 2022)
			91,7%	(Khan et al., 2019)
A4	Algoritmo FEDQUAKE	Una variación del algoritmo federado promediado con orientación a la predicción de movimientos sísmicos (Tehseen et al., 2021).	81,63%	(Ria et al., 2021)
			88,87%	(Tehseen et al., 2021)
A5	Naive Bayes	Es el representante más simple de los algoritmos basados en probabilidades. Está basado en el teorema de Bayes (Benítez et al., 2014).	88,4%	(Hashi et al., 2021)
			76,41%	(Ria et al., 2021)
A6	CNN (redes neuronales convolucionales)	Es una construcción de código matemático, tiene tres tipos de capas conocidas como bloques de construcción (Mesa, 2021).	87%	(Hashi et al., 2021)
			92%	(Kavzoglu et al., 2021)

A7	SVC (Clasificador de Vectores de Soporte)	Es un algoritmo emergente usado exitosamente en problemas de clasificación y regresión (Mesa, 2021).	98%	(Yaseen et al., 2022)
A8	MLP (Red Neuronal Multicapa)	Están inspiradas en las redes neuronales biológicas del cerebro humano. Presentan características propias del cerebro (Torres López et al., 2016) .	98%	(Yaseen et al., 2022)
A9	Holt-Winters	Herramienta para el pronóstico de series temporales con patrones de tendencia y estacionalidad (Kalekar, s. f.).	94,9%	(Kaur & Sood, 2020)
A10	BFGS (Broyden–Fletcher–Goldfarb)	Se utiliza para la optimización sin restricciones de funciones no lineales (Saputro & Widyaningsih, 2017).	88%	(Ahmed et al., 2022)
A11	CG (gradiente conjugado)	Genera secuencias de vectores $\hat{r}$ y residuos, y direcciones de búsqueda las cuales emplea para actualizar a los vectores y residuos durante cada iteración (Sosa Cordova, 2014).	81%	(Ahmed et al., 2022)
A12	ConvLSTM (Memoria a Corto y Largo Plazo Convolutiva)	Determina el estado futuro de una celda específica en la cuadrícula utilizando las entradas y los estados pasados de sus vecinos locales, utiliza un operador de convolución en las transiciones de estado a estado y de entrada a estado (SHI et al., 2015).	73%	(Moishin et al., 2021)
A13	LSTM (Memoria a Corto y Largo Plazo)	permite que una red aprenda relaciones a largo plazo entre unidades temporales en series de tiempo y datos secuenciales	71%	(Moishin et al., 2021)
		(Memoria de corto-largo plazo - MATLAB lstm - MathWorks América Latina, s. f.).	86%	(Kavzoglu et al., 2021)
			71%	(Moishin et al., 2021)

A14	SVR (Regresión de Vectores de Soporte)	Sirve para clasificar, se utiliza como un esquema de regresión para predecir valores (Ríos et al., 2019).	41%	(Moishin et al., 2021)
A15	estación 1 – ANFIS (Sistema Adaptativo de Inferencia Neuro-Difusa)	Es un modelo híbrido donde las reglas se aplican siguiendo una estructura de red tipo neuronal	94,4%	(Sahoo et al., 2021)
	estación 2 – ANFIS	(Sánchez & Villamar, s. f.).	94,8%	
A16	estación 1 - ANFIS-GOA (Grey Wolf Optimizer)	Es un modelo híbrido que combina la capacidad de aprendizaje del ANFIS	97,4%	(Sahoo et al., 2021)
	estación 2 - ANFIS-GOA	con la potencia de optimización del GOA (Penghui et al., 2020).	97,5%	
A17	estación 1 - ANFIS-GWO (Grey Wolf Algorithm)	Herramienta robusta para resolver problemas complejos de predicción y	96%	(Sahoo et al., 2021)
	estación 2 - ANFIS-GWO	modelado, aprovecha la capacidad de aprendizaje y manejo de incertidumbre junto con la optimización (Paryani et al., 2020).	97,5%	
A18	Precisión media media a nivel de imagen (ImAP)	Métrica de evaluación utilizada en el campo de la visión por computadora para medir el rendimiento de los modelos de detección de objetos en imágenes (<i>Item 1009/1308 Repositorio INAOE</i> , 2018).	98,46%	(Tzimas et al., 2023)
A19	Gradient Boosting Regression Plus (GBP+)	Aplicada en problemas de regresión, incorpora técnicas avanzadas que mejoran el rendimiento y la precisión (Defontaine et al., 2023).	98,9%	(Defontaine et al., 2023)
A20	VGG16	Es una red neuronal convolucional con 16 capas de profundidad (<i>Red neuronal convolucional</i> , s. f.).	95,46%	(Sathishkumar et al., 2023)
			96%	(Jain et al., 2020)
A21	InceptionV3	Ofrece alta precisión en tareas de clasificación de imágenes, manteniendo al mismo tiempo la eficiencia computacional (Xia et al., 2017).	97.01%	(Sathishkumar et al., 2023)

A22	Xception	Mejorar la eficiencia computacional y el rendimiento en tareas de visión por computadora (Chollet, 2017).	98,72%	(Sathishkumar et al., 2023)
A23	ANN (Red Neuronal Artificial)	Se basa en el intento de modelar la forma en que un cerebro biológico procesa datos (Agatonovic-Kustrin & Beresford, 2000).	66,67%	(Ntinopoulos et al., 2023)
			98.03%	(Sanubari et al., 2018)
			97%	(Moreno et al., 2023)
A24	RBF (Función de Base Radial)	Proporcionan una alternativa flexible y efectiva para abordar problemas de regresión, clasificación y aproximación de funciones (Filali Bouami, 2005).	83,33%	(Ntinopoulos et al., 2023)
A25	PANet,	Modelo de red neuronal diseñado específicamente para abordar problemas de segmentación semántica en imágenes (Erazo Samboni, 2023).	73,36%	(Tran-Anh et al., 2022)
A26	PFENet	Mejora la extracción y fusión de características de diferentes niveles de escala en imágenes (Liu et al., 2022).	76,45%	(Tran-Anh et al., 2022)
A27	HSNet	Contiene un módulo de atención semántica cruzada, un módulo complementario semántico híbrido y un módulo de predicción multiescala (W. Zhang et al., 2022)	80,94%	[19]
A28	ASNet	Es una estructura donde las conexiones no son simétricas en términos de funciones o capacidades entre diferentes partes o capas de la red (S. Zhang et al., 2020).	82,43%	(Tran-Anh et al., 2022)
A29	CFASNet	Optimiza la manera en que se capturan las imágenes, mejorando así el rendimiento en tareas de visión por computadora (Salam et al., 2020).	83,21%	(Tran-Anh et al., 2022)

A30	LightEQ	Tecnología avanzada de procesamiento de imágenes que se implementa en cámaras para mejorar la calidad de imagen (Zainab et al., 2023).	99,5%	(Zainab et al., 2023)
A31	Algoritmo de Optimización por Enjambre de Partículas (PSO)	Es un método de optimización heurística orientado a encontrar mínimos o máximos globales (Sengupta et al., 2018).	94,47%	(Supriya & Gadekallu, 2023)
A32	Algoritmo de entrenamiento de LevenbergMarquardt (trainlm)	El algoritmo trainlm puede entrenar cualquier red siempre que sus funciones de peso, entrada neta y transferencia tengan funciones derivadas (Kipli et al., 2012).	75%	(Zulkifli et al., 2022)
A33	Red neuronal recurrente (RNN)	Conocidas por su capacidad para procesar y obtener información de datos secuenciales (Arana, s. f.).	91%	(Kavzoglu et al., 2021)
A34	Árbol de decisión	Representa reglas de clasificación inherentes a los datos, con una estructura en árbol que particiona los datos de manera recursiva (Benítez et al., 2014).	81,21%	(Ria et al., 2021)
			93,22%	(Aswad et al., 2022)
			84,2%	(Hashi et al., 2021)
A35	Regresión logística	Es un instrumento estadístico de análisis multivariado, de uso tanto explicativo como predictivo (Chitarroni, 2002).	80,38%	(Ria et al., 2021)
A36	Decisión Jungle	es un conjunto de DAGs, tienen la misma estructura que un árbol de decisión, con nodos y aristas, con la diferencia de que estos nodos pueden venir de otros múltiples nodos (Díaz & Ignacia, 2019).	77,38%	(Aswad et al., 2022)
A37	Aprendizaje de similitud	Emplea métodos de clasificación para el aprendizaje de medidas de similitud. Su rendimiento depende en gran medida de la representación de	90%	(Peng et al., 2019)

		las características de los datos disponibles (López-Iñesta, 2017).		
A38	SOINN (Red Neuronal Incremental Autoorganizada)	Una clase de redes neuronales diseñadas para el aprendizaje continuo a partir de datos no estacionarios (Wiwatcharakoses & Berrar, 2020).	96%	(Kim & Hasegawa, 2018)

Como se evidencia en la tabla 5 el algoritmo más empleado es Bosques aleatorios con un total de 6 referencias dentro de la literatura estudiada para este trabajo mencionando que en uno de estos es el estudio que presenta mejores resultados en la evaluación con un 99% de eficiencia predictiva. Pero también podemos notar que el modelo ANFIS a pesar de que solo se presenta en un trabajo, pero con ciertas variaciones (apoyándose en los algoritmos GOA y GWO) que hacen más robusta la evaluación de su precisión, contando con umbrales de un rango entre 97,5% y 94,4%.

De forma sintetizada, se matizan dos trabajos, en (Yaseen et al., 2022) se comparan tres algoritmos, el de mayor precisión es RF, alcanzando el 99% en las pruebas de validación cruzada, mientras que MLP y SVC obtuvieron una precisión de 98% cada uno. Este trabajo hace notar que los tres algoritmos empleados obtuvieron buenos resultados gracias a la combinación de características distintas que mejoran el rendimiento de los algoritmos. Por otra parte, en el estudio (Sahoo et al., 2021) se investiga el potencial del modelo ANFIS, en combinación con los algoritmos GOA y GWO, donde se evidencia que el mejor desempeño lo obtiene ANFIS-GOA sobre ANFIS-GWO Y ANFIS convencional, que a pesar de no ser modelos y/o algoritmos muy conocidos o implementados obtienen buenos porcentajes de exactitud, además se denota que integrar algoritmos de optimización resulta ser mucho más efectivo y preciso que la IA habitual.

Conclusiones

Se llevó a cabo una revisión sistemática de la literatura sobre “Técnicas de Inteligencia Artificial en la Predicción de Desastres Naturales” teniendo como enfoque central determinar las tendencias sobre las Técnicas de IA y los algoritmos implementadas en este campo, en conjunto a su precisión. Para lograr este objetivo se identificaron 1580 artículos potenciales de los cuales fueron sometidos a diversos procesos de selección dando como resultado la inclusión de 28 trabajos investigativos.

Al analizar las aplicaciones y el enfoque de estas en el tópico, se evidencia que el desastre natural más estudiado y que mejor se puede mitigar con la aplicación de las técnicas de IA son las inundaciones con una recurrencia del 72,73 % dentro de la literatura revisada. Del mismo modo se identificaron las principales técnicas de inteligencia artificial aplicadas en la predicción de desastres naturales, llegando a la conclusión que la más empleada es el Aprendizaje automático con un 46,3% de reiteración entre la literatura examinada.

Aunque algunos autores divergen entre la definición de técnicas de IA y algoritmos, para este trabajo se interpretó con base en las revisiones que; una técnica de IA es una metodología específica diseñada para abordar desafíos y un algoritmo es una secuencia de pasos para resolver problemas y teniendo claras estas definiciones se determina que el algoritmo más utilizado es RF entre el material analizado, pero los que más precisión muestran son la combinación del modelo ANFIS con los algoritmos GOA y GWO con una precisión entre 97,5% y 94,4%. Esto indica que la predicción con mejores resultados en las evaluaciones de los modelos empleados depende de dos factores principales identificados; los datos brutos o características consideradas para la predicción y el empleo de algoritmos o modelos combinados. De esta manera, se infiere que se pueden mejorar aún más los resultados de una predicción, con la selección idónea de los datos a considerar en conjunto con algoritmos optimizados y compatibles

entre sí. En este contexto es importante destacar que la aplicación de técnicas de inteligencia artificial en la predicción de desastres naturales nos muestra un progreso considerable junto a los algoritmos y modelos que contribuyen a la precisión de estas técnicas, no obstante, es importante continuar mejorando la adquisición y fiabilidad de datos así como integrar enfoques híbridos para así potenciar al máximo las capacidades predictivas de la IA y de esta manera mitigar los riesgos que ocasionen los desastres naturales.

Referencias Bibliográficas

- Abdollahi, A., & Pradhan, B. (2023). Explainable artificial intelligence (XAI) for interpreting the contributing factors feed into the wildfire susceptibility prediction model. *Science of The Total Environment*, 879, 163004. <https://doi.org/10.1016/j.scitotenv.2023.163004>
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717-727. [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1)
- Ahmad, K., Khan, M. S., Ahmed, F., Driss, M., Boulila, W., Alazeb, A., Alsulami, M., Alshehri, M. S., Ghadi, Y. Y., & Ahmad, J. (2023). FireXnet: An explainable AI-based tailored deep learning model for wildfire detection on resource-constrained devices. *Fire Ecology*, 19(1). Scopus. <https://doi.org/10.1186/s42408-023-00216-0>
- Ahmed, F., Loc, H. H., Park, E., Hassan, M., & Joyklad, P. (2022). Comparison of Different Artificial Intelligence Techniques to Predict Floods in Jhelum River, Pakistan. *Water*, 14(21), 3533. <https://doi.org/10.3390/w14213533>
- Alonso, A. D. C., & Jara, E. A. M. (2016). Visión por computadora: Identificación, clasificación y seguimiento de objetos. *FPUNE Scientific*, 10, Article 10. <http://servicios.fpune.edu.py:83/fpunescientific/index.php/fpunescientific/article/view/137>
- Aracena, C., Villena, F., Arias, F., & Dunstan, J. (2022). Aplicaciones de aprendizaje automático en salud. *Revista Médica Clínica Las Condes*, 33(6), 568-575. <https://doi.org/10.1016/j.rmcl.2022.10.001>
- Arana, C. (s. f.). *Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales*.
- Arinta, R. R., & Andi W.R., E. (2019). Natural Disaster Application on Big Data and Machine Learning: A Review. *2019 4th International Conference on Information Technology*,
-

- Information Systems and Electrical Engineering (ICITISEE)*, 249-254.
<https://doi.org/10.1109/ICITISEE48480.2019.9003984>
- Arjona, M. A. C., Rosado, V. M. B., Burgos, J. A. V., & Collí, M. A. P. (2017). Estudio comparativo de técnicas de minería de datos para la predicción de rutas de huracanes: Comparative study of data mining techniques for the prediction of hurricane routes. *Tecnología Educativa Revista CONAIC*, 4(1), Article 1. <https://doi.org/10.32671/terc.v4i1.113>
- Aswad, F. M., Kareem, A. N., Khudhur, A. M., Khalaf, B. A., & Mostafa, S. A. (2022). Tree-based machine learning algorithms in the Internet of Things environment for multivariate flood status prediction. *Journal of Intelligent Systems*, 31(1), 1-14. <https://doi.org/10.1515/jisys-2021-0179>
- Banafa, A. (2023, octubre 9). Artificial Intelligence and Natural Disasters. *OpenMind*. <https://www.bbvaopenmind.com/en/technology/artificial-intelligence/artificial-intelligence-and-natural-disasters/>
- Benítez, R., Escudero, G., Kanaan, S., & Rodó, D. M. (2014). *Inteligencia artificial avanzada*. Editorial UOC.
- Bhargavi, K. N., & Suma, G. J. (2020). Quasi Analysis of Rainfall Prediction during Floods using Machine Learning. *Proceedings of the 2020 8th International Conference on Communications and Broadband Networking*, 63-67. <https://doi.org/10.1145/3390525.3390535>
- Bhowmik, R. T., Jung, Y. S., Aguilera, J. A., Prunicki, M., & Nadeau, K. (2023). A multi-modal wildfire prediction and early-warning system based on a novel machine learning framework. *Journal of Environmental Management*, 341. Scopus. <https://doi.org/10.1016/j.jenvman.2023.117908>
- Bolt, B. A. (2022). *Terremotos*. Reverte.
- Botana, G. de J. (s. f.). *APRENDIZAJE AUTOMÁTICO SUPERVISADO*.
- Catástrofes naturales globales 2010-2022 | Statista*. (s. f.). Recuperado 18 de junio de 2024, de <https://es.statista.com/estadisticas/641148/catastrofes-naturales-a-nivel-mundial/>
- Chen, M., Li, Z., Gao, S., Xue, M., Gourley, J. J., Kolar, R. L., & Hong, Y. (2022). A flood predictability study for Hurricane Harvey with the CREST-iMAP model using high-resolution quantitative precipitation forecasts and U-Net deep learning precipitation nowcasts. *Journal of Hydrology*, 612, 128168. <https://doi.org/10.1016/j.jhydrol.2022.128168>
- Chitarroni, H. (2002). *La regresión logística*. IDICSO. <https://racimo.usal.edu.ar/83/1/Chitarroni17.pdf>
-

- Chollet, F. (2017). *Xception: Deep Learning With Depthwise Separable Convolutions*. 1251-1258. https://openaccess.thecvf.com/content_cvpr_2017/html/Chollet_Xception_Deep_Learning_CVPR_2017_paper.html
- ¿Cómo se predice las inundaciones? (2024, mayo 9). Gidahatari. <https://gidahatari.com/ih-es/como-se-predice-las-inundaciones>
- Defontaine, T., Ricci, S., Lapeyre, C., Marchandise, A., & Pape, E. L. (2023). Flood forecasting with Machine Learning in a scarce data layout. *IOP Conference Series: Earth and Environmental Science*, 1136(1), 012020. <https://doi.org/10.1088/1755-1315/1136/1/012020>
- Díaz, R., & Ignacia, M. (2019). *Análisis predictivo de activos mineros para obtención de intervalo de falla mediante algoritmos de machine learning*. <https://repositorio.uchile.cl/handle/2250/173707>
- Erazo Samboni, W. R. (2023). *Desarrollo de aplicación Android móvil utilizando Visión Artificial y Deep Learning para la identificación de aguacates Hass con la plaga Monalonia, en la finca “Las Palmas”, ubicada en el municipio de San Agustín, Huila*. <http://repositorio.uan.edu.co/handle/123456789/7904>
- Filali Bouami, M. (2005). *Desarrollo y optimización de nuevos modelos de redes neuronales basadas en funciones de base radial: Tesis doctoral*. Editorial de la Universidad de Granada.
- Gahete Morillo, C. (2023). *Predicción de variables macroeconómicas*. <https://repositorio.comillas.edu/xmlui/handle/11531/75364>
- Gelbukh, A. (2010). Procesamiento de lenguaje natural y sus aplicaciones. *Artículo invitado. Komputer Sapiens*, ISSN. https://www.academia.edu/2817247/Procesamiento_de_lenguaje_natural_y_sus_aplicaciones
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental Concepts of Convolutional Neural Network. En V. E. Balas, R. Kumar, & R. Srivastava (Eds.), *Recent Trends and Advances in Artificial Intelligence and Internet of Things* (pp. 519-567). Springer International Publishing. https://doi.org/10.1007/978-3-030-32644-9_36
- Hashi, A. O., Abdirahman, A. A., Elmi, M. A., Hashi, S. Z. M., & Rodriguez, O. E. R. (2021). A Real-Time Flood Detection System Based on Machine Learning Algorithms with Emphasis on Deep Learning. *International Journal of Engineering Trends and Technology*, 69(5), 249-256. <https://doi.org/10.14445/22315381/IJETT-V69I5P232>
-

- Herrera Delgado, V. (2021). *Desarrollo de una red neuronal profunda para la clasificación y caracterización de prendas de vestir*.
<https://accedacris.ulpgc.es/jspui/handle/10553/77987>
- Item 1009/1308 | Repositorio INAOE. (2018, agosto 31).
<http://inaoe.repositorioinstitucional.mx/jspui/handle/1009/1308>
- Jain, P., Schoen-Phelan, B., & Ross, R. (2020). Automatic flood detection in Sentinel-2 images using deep convolutional neural networks. *Proceedings of the 35th Annual ACM Symposium on Applied Computing*, 617-623. <https://doi.org/10.1145/3341105.3374023>
- Jason, Z. C. (2015). *Ing. Mónica Carolina Roncal Mujica*.
- Kalekar, P. S. (s. f.). *Time series Forecasting using Holt-Winters Exponential Smoothing*.
- Kaur, A., & Sood, S. K. (2020). Artificial Intelligence-Based Model For Drought Prediction and Forecasting. *The Computer Journal*, 63(11), 1704-1712.
<https://doi.org/10.1093/comjnl/bxz105>
- Kavzoglu, T., Teke, A., & Yilmaz, E. O. (2021). Shared Blocks-Based Ensemble Deep Learning for Shallow Landslide Susceptibility Mapping. *Remote Sensing*, 13(23), 4776.
<https://doi.org/10.3390/rs13234776>
- Khalaf, M., Alaskar, H., Hussain, A. J., Baker, T., Maamar, Z., Buyya, R., Liatsis, P., Khan, W., Tawfik, H., & Al-Jumeily, D. (2020). IoT-Enabled Flood Severity Prediction via Ensemble Machine Learning Models. *IEEE Access*, 8, 70375-70386.
<https://doi.org/10.1109/ACCESS.2020.2986090>
- Khan, T. A., Alam, M., Ahmed, S. F., Shahid, Z., & Mazliham, M. S. (2019). A Factual Flash Flood Evaluation using SVM and K-NN. *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, 1-6.
<https://doi.org/10.1109/ICETAS48360.2019.9117424>
- Khan, T. A., Alam, M. M., Shahid, Z., & Su'Ud, M. M. (2020). Investigation of Flash Floods on Early Basis: A Factual Comprehensive Review. *IEEE Access*, 8, 19364-19380.
<https://doi.org/10.1109/ACCESS.2020.2967496>
- Kim, W., & Hasegawa, O. (2018). Time Series Prediction of Tropical Storm Trajectory Using Self-Organizing Incremental Neural Networks and Error Evaluation. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 22(4), 465-474.
<https://doi.org/10.20965/jaciii.2018.p0465>
- Kipli, K., Muhammad, M. S., Masra, S. M. W., Zamhari, N., Lias, K., & Mat, D. A. A. (2012). Performance of Levenberg-Marquardt Backpropagation for Full Reference Hybrid Image Quality Metrics. *Hong Kong*.

- Latorre, A. S. D. (2019). *APRENDIZAJE POR REFUERZO PARA CONTROL DE SISTEMAS DINÁMICOS*.
- Linkedin. (s. f.). *¿Cuáles son algunos ejemplos de modelos lineales y no lineales en aplicaciones del mundo real?* Recuperado 28 de mayo de 2024, de <https://es.linkedin.com/advice/0/what-some-examples-linear-nonlinear-models-real-world?lang=es>
- Liu, L., Feng, W., Chen, C., Liu, M., Qu, Y., & Yang, J. (2022). Classification of breast cancer histology images using MSMV-PFENet. *Scientific Reports*, 12(1), 17447. <https://doi.org/10.1038/s41598-022-22358-y>
- López-Iñesta, E. (2017). *Aprendizaje de similitudes entre pares de objetos mediante clasificación supervisada / Learning of similarities between pairs of objects by using supervised classification*.
- Marcos Valiente, O. (2001). Sequía: Definiciones, tipologías y métodos de cuantificación. *Investigaciones Geográficas (España)*, 26, 59-80.
- Memoria de corto-largo plazo—MATLAB lstm—MathWorks América Latina. (s. f.). Recuperado 24 de junio de 2024, de <https://la.mathworks.com/help/deeplearning/ref/dlarray.lstm.html>
- Méndez Garabetti, M. (2022). *Método de reducción de incertidumbre basado en algoritmos evolutivos y paralelismo orientado a la predicción y prevención de desastres naturales*. Editorial de la Universidad Nacional de La Plata (EDULP). <http://sedici.unlp.edu.ar/handle/10915/135115>
- Mesa, F. A. (2021). El análisis de eficiencia de la red neuronal convolucional (cnn) y el sistema de aprendizaje tensorflow. *Investigación y Ciencia Aplicada a la Ingeniería*, 4(27), Article 27.
- Moishin, M., Deo, R. C., Prasad, R., Raj, N., & Abdulla, S. (2021). Designing Deep-Based Learning Flood Forecast Model With ConvLSTM Hybrid Algorithm. *IEEE Access*, 9, 50982-50993. <https://doi.org/10.1109/ACCESS.2021.3065939>
- Montañés Salas, R. M., & Hoyo Alonso, R. del. (2019). *Análisis de sentimiento con aprendizaje profundo en un entorno de Big Data*. Universidad de Zaragoza.
- Moreno Castillo, J. M. (2019). *Generación y simulación de un modelo predictivo para prevenir inundaciones en viviendas aledañas a zonas de riesgo mediante técnicas de inteligencia artificial*. <http://repository.udistrital.edu.co/handle/11349/16327>
- Moreno, H. T., Márquez, R. J. G., Lengua, M. A. C., & Andrade-Arenas, L. (2023). Model of Neural Networks: Probabilistic Prediction of Floods in Banana Agricultural Field. *International*
-

- Journal of Engineering Trends and Technology*, 71(1), 124-133.
<https://doi.org/10.14445/22315381/IJETT-V71I1P211>
- Murillo Gutiérrez, M., Zuluaga Villegas, D. I., Velasco Escobar, L. A., Atehortúa García, O., Castrillón Rivas, M., Castaño Tovar, D., Duque Escobar, J., & Henao Salazar, C. (1991). Hablemos sobre los deslizamientos de tierra. En *Hablemos sobre los deslizamientos de tierra* (pp. 52-52). <http://www.crid.or.cr/digitalizacion/pdf/spa/doc1162/doc1162.htm>
- Narvaez, J. F. (2017). *Desarrollos de la Ingeniería ambiental en la evaluación de la calidad de los recursos naturales y la salud ambiental*. (pp. 212-225).
- Ntinopoulos, N., Sakellariou, S., Christopoulou, O., & Sfougaris, A. (2023). Fusion of Remotely-Sensed Fire-Related Indices for Wildfire Prediction through the Contribution of Artificial Intelligence. *Sustainability*, 15(15), 11527. <https://doi.org/10.3390/su151511527>
- Paryani, S., Neshat, A., Javadi, S., & Pradhan, B. (2020). Comparative performance of new hybrid ANFIS models in landslide susceptibility mapping. *Natural Hazards*, 103(2), 1961-1988. <https://doi.org/10.1007/s11069-020-04067-9>
- Pausas, J. G. (2020). *Incendios forestales*. Los Libros De La Catarata.
- Peng, B., Liu, X., Meng, Z., & Huang, Q. (2019). Urban Flood Mapping with Residual Patch Similarity Learning. *Proceedings of the 3rd ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery*, 40-47. <https://doi.org/10.1145/3356471.3365235>
- Penghui, L., Ewees, A. A., Beyaztas, B. H., Qi, C., Salih, S. Q., Al-Ansari, N., Bhagat, S. K., Yaseen, Z. M., & Singh, V. P. (2020). Metaheuristic Optimization Algorithms Hybridized With Artificial Intelligence Model for Soil Temperature Prediction: Novel Model. *IEEE Access*, 8, 51884-51904. <https://doi.org/10.1109/ACCESS.2020.2979822>
- ¿Qué es la IA predictiva? (s. f.). Recuperado 25 de junio de 2024, de <https://www.cloudflare.com/es-es/learning/ai/what-is-predictive-ai/>
- Red neuronal convolucional. (s. f.). Recuperado 24 de junio de 2024, de <https://la.mathworks.com/help/deeplearning/ref/vgg16.html>
- Restrepo Arteaga, G. J. P. (2015). *Aplicación del aprendizaje profundo (deep learning) al procesamiento de señales digitales*. <https://red.uao.edu.co/entities/publication/614df0e9-3299-43e1-9f3c-c3351e38b59f>
- Ria, N. J., Ani, J. F., Islam, M., & Masum, A. K. M. (2021). Standardization Of Rainfall Prediction In Bangladesh Using Machine Learning Approach. *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1-5. <https://doi.org/10.1109/ICCCNT51525.2021.9579472>
-

- Ríos, J., Ulla, G., & Borello Gianni, A. (2019). *Aplicación de regresión con vectores de soporte en un sistema recomendador de actividades sociales*. XXV Congreso Argentino de Ciencias de la Computación (CACIC) (Universidad Nacional de Río Cuarto, Córdoba, 14 al 18 de octubre de 2019). <http://sedici.unlp.edu.ar/handle/10915/90892>
- Rouhiainen, L. (2018). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*.
- Saad, O. M., Chen, Y., Savvaidis, A., Fomel, S., Jiang, X., Huang, D., Oboué, Y. A. S. I., Yong, S., Wang, X., Zhang, X., & Chen, Y. (2023). Earthquake Forecasting Using Big Data and Artificial Intelligence: A 30-Week Real-Time Case Study in China. *Bulletin of the Seismological Society of America*, 113(6), 2461-2478. <https://doi.org/10.1785/0120230031>
- Sahoo, A., Samantaray, S., & Paul, S. (2021). Efficacy of ANFIS-GOA technique in flood prediction: A case study of Mahanadi river basin in India. *H2Open Journal*, 4. <https://doi.org/10.2166/h2oj.2021.090>
- Salam, A., Javaid, Q., & Ahmad, M. (2020). Bioinspired Mobility-Aware Clustering Optimization in Flying Ad Hoc Sensor Network for Internet of Things: BIMAC-FASNET. *Complexity*, 2020, 1-20. <https://doi.org/10.1155/2020/9797650>
- San Martín Neira, L. (2019). Desastres naturales y responsabilidad civil. Identificación de los desafíos que presenta esta categoría de hechos dañinos. *Revista de derecho (Valdivia)*, 32(2), 123-142. <https://doi.org/10.4067/S0718-09502019000200123>
- Sánchez, C. S. A., & Villamar, C. J. (s. f.). *APLICACIÓN DEL MODELO ANFIS A LA SINTETIZACION DE NOTAS MUSICALES Y SEÑALES DE VOZ*.
- Sandoval Serrano, L. J. (2018). *Algoritmos de aprendizaje automático para análisis y predicción de datos*. <http://redicces.org.sv/jspui/handle/10972/3626>
- Sanubari, A. R., Kusuma, P. D., & Setianingsih, C. (2018). Flood Modelling and Prediction Using Artificial Neural Network. *2018 IEEE International Conference on Internet of Things and Intelligence System (IOTAIS)*, 227-233. <https://doi.org/10.1109/IOTAIS.2018.8600869>
- Saputro, D. R. S., & Widyaningsih, P. (2017). Limited memory Broyden-Fletcher-Goldfarb-Shanno (L-BFGS) method for the parameter estimation on geographically weighted ordinal logistic regression model (GWOLR). *AIP Conference Proceedings*, 1868(1), 040009. <https://doi.org/10.1063/1.4995124>
- Sathishkumar, V. E., Cho, J., Subramanian, M., & Naren, O. S. (2023). Forest fire and smoke detection using deep learning-based learning without forgetting. *Fire Ecology*, 19(1), 9. <https://doi.org/10.1186/s42408-022-00165-0>
-

- Sengupta, S., Basak, S., & Peters, R. (2018). Particle Swarm Optimization: A Survey of Historical and Recent Developments with Hybridization Perspectives. *Machine Learning and Knowledge Extraction*, 1(1), 157-191. <https://doi.org/10.3390/make1010010>
- SHI, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W., & WOO, W. (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Advances in Neural Information Processing Systems*, 28. https://proceedings.neurips.cc/paper_files/paper/2015/hash/07563a3fe3bbe7e3ba84431ad9d055af-Abstract.html
- Sosa Cordova, S. A. (2014). *Implementación del método gradiente conjugado en un FPGA arquitectura Spartan 6*. <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/5464>
- Supriya, Y., & Gadekallu, T. R. (2023). Particle Swarm-Based Federated Learning Approach for Early Detection of Forest Fires. *Sustainability*, 15(2), 964. <https://doi.org/10.3390/su15020964>
- Tamayo Carmona, J., & Núñez Mora, J. Á. (2020). Precipitaciones intensas en la Comunidad Valenciana: Análisis, sistemas de predicción y perspectivas ante el cambio climático. *Riesgo de inundación en España: análisis y soluciones para la generación de territorios resilientes*, 2020, ISBN 978-84-1302-091-4, págs. 49-62, 49-62. <https://dialnet.unirioja.es/servlet/articulo?codigo=7578907>
- Tehseen, R., Farooq, M. S., & Abid, A. (2021). A framework for the prediction of earthquake using federated learning. *PeerJ Computer Science*, 7, e540. <https://doi.org/10.7717/peerj-cs.540>
- Torres López, S., Aldana Cuza, M. L., Piñero Perez, P. Y., & Piedra Diéguez, L. A. (2016). Red neuronal multicapa para la evaluación de competencias laborales. *Revista Cubana de Ciencias Informáticas*, 10, 210-223.
- Tran-Anh, D., Bui-Quoc, B., Vu-Duc, A., Do, T.-A., Viet, H. N., Vu, H.-N., & Tran, C. (2022). Integrative Few-Shot Classification and Segmentation for Landslide Detection. *IEEE Access*, 10, 120200-120212. <https://doi.org/10.1109/ACCESS.2022.3220906>
- Tzimas, M. D., Papaioannidis, C., Mygdalis, V., & Pitas, I. (2023). Evaluating Deep Neural Network-based Fire Detection for Natural Disaster Management. *Proceedings of the IEEE/ACM 10th International Conference on Big Data Computing, Applications and Technologies*, 1-6. <https://doi.org/10.1145/3632366.3632369>
- Wiwatcharakoses, C., & Berrar, D. (2020). SOINN+, a Self-Organizing Incremental Neural Network for Unsupervised Learning from Noisy Data Streams. *Expert Systems with Applications*, 143, 113069. <https://doi.org/10.1016/j.eswa.2019.113069>
-

- Xia, X., Xu, C., & Nan, B. (2017). Inception-v3 for flower classification. *2017 2nd International Conference on Image, Vision and Computing (ICIVC)*, 783-787. <https://doi.org/10.1109/ICIVC.2017.7984661>
- Yaseen, M. W., Awais, M., Riaz, K., Rasheed, M. B., Waqar, M., & Rasheed, S. (2022). Artificial Intelligence Based Flood Forecasting for River Hunza at Danyor Station in Pakistan. *Archives of Hydro-Engineering and Environmental Mechanics*, 69(1), 59-77. <https://doi.org/10.2478/heem-2022-0005>
- Zainab, T., Karstens, J., & Landsiedel, O. (2023). LightEQ: On-Device Earthquake Detection with Embedded Machine Learning. *Proceedings of the 8th ACM/IEEE Conference on Internet of Things Design and Implementation*, 130-143. <https://doi.org/10.1145/3576842.3582387>
- Zhang, S., Zhang, L., Wang, W., & Wu, X. (2020). AsNet: Asymmetrical Network for Learning Rich Features in Person Re-Identification. *IEEE Signal Processing Letters*, 27, 850-854. <https://doi.org/10.1109/LSP.2020.2994815>
- Zhang, W., Fu, C., Zheng, Y., Zhang, F., Zhao, Y., & Sham, C.-W. (2022). HSNet: A hybrid semantic network for polyp segmentation. *Computers in Biology and Medicine*, 150, 106173. <https://doi.org/10.1016/j.compbiomed.2022.106173>
- Zulkifli, Z. Z., Mamat, M., & Yew, H. T. (2022). River Water Level Prediction for Flood Risk Assessment using NARX Neural Network. *2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAET)*, 1-6. <https://doi.org/10.1109/IICAET55139.2022.9936739>
-