

PANORAMA ACTUAL DEL USO DE LA INTELIGENCIA ARTIFICIAL EN DESASTRES NATURALES, UNA REVISIÓN DE LA LITERATURA

CURRENT OVERVIEW OF THE USE OF ARTIFICIAL INTELLIGENCE IN NATURAL DISASTERS: A LITERATURE REVIEW

Pedro Gustavo Montesinos Berrocal^{1*}, José Alfredo Herrera Quispe¹, Katherina Changanahui Barrientos²

RESUMEN

Los desastres naturales han aumentado en los últimos años provocados por el cambio climático, generando un número significativo de damnificados y una creciente necesidad de contar con sistemas eficientes de monitoreo y clasificación. Este estudio presenta una revisión panorámica de las principales tecnologías de inteligencia artificial (IA) y el monitoreo automático aplicadas a la fase de conocimiento del riesgo en la gestión de desastres. Se describen los principales tipos de desastres naturales tales como inundaciones, incendios forestales, terremotos, deslizamientos de tierra, ciclones tropicales, sequía, huracanes, tsunamis, deforestación y avalanchas de nieve. Asimismo, se describen las herramientas tecnológicas, algoritmos de IA, empleadas para su análisis, entre ellas: (Big Data, visión computacional, IoT, LLM y otros). Además, se identificaron los modelos de IA más utilizados en la investigación como máquinas de soporte vectorial (SVM), bosques aleatorios (RF), redes neuronales LSTM y árboles de decisión (DT). Comprender los tipos de desastres y las tecnologías aplicadas a su predicción y detección permitirá identificar nuevos nichos de investigación. Asimismo, conocer los modelos y tecnologías en la literatura científica orienta el desarrollo de sistemas inteligentes de gestión del riesgo y mejora la efectividad en la construcción de equipos de respuesta ante emergencias.

Palabras clave: Desastre natural, predicción, detección, inteligencia artificial, gestión del riesgo.

ABSTRACT

Natural disasters have increased in recent years due to climate change, resulting in a significant number of victims and a growing need for efficient monitoring and classification systems. This study presents an overview of the main artificial intelligence (AI) technologies and automated monitoring applied to the risk assessment phase of disaster management. It describes the main types of natural disasters, such as floods, forest fires, earthquakes, landslides, tropical cyclones, drought, hurricanes, tsunamis, deforestation, and avalanches. It also examines the technological tools and AI algorithms used for their analysis, including Big Data, computer vision, IoT, LLM, and others. Furthermore, it identifies the most commonly used AI models in research, such as support vector machines (SVMs), random forests (RF), LSTM neural networks, and decision trees (DTs). Understanding the types of disasters and the technologies applied to their prediction and detection will allow for the identification of new research areas. Likewise, understanding the models and technologies in the scientific literature guides the development of intelligent risk management systems and improves the effectiveness in building emergency response teams.

Keywords: Natural disaster, prediction, detection, artificial intelligence, risk management.

¹ ITData, Facultad de Ingeniería de Sistemas e Informática, Universidad Nacional Mayor de San Marcos

² Facultad de Ciencias, Universidad Nacional de Ingeniería

*Autor de Correspondencia: pedromontesinosb@gmail.com

1. INTRODUCCIÓN

Los desastres naturales continúan representando una amenaza global significativa, y su frecuencia e intensidad se han visto incrementadas como consecuencia del cambio climático, afectando de manera significativa a la población y los ecosistemas (Knutson, T., Camargo, S. J., Chan, J. C. L., Emanuel, K., Ho, C.-H., Kossin, J., Mohapatra, M., Satoh, M., Sugi, M., Walsh, K., & Wu, 2020; Peduzzi et al., 2012). Fenómenos como huracanes, incendios forestales, inundaciones y deslizamientos de tierra afectan tanto a regiones vulnerables como a países con economías desarrolladas, provocando pérdidas humanas y materiales cada vez más severas (Boroujeni et al., 2024).

En este contexto, el desarrollo de sistemas inteligentes de detección temprana de desastres naturales se ha convertido en una prioridad estratégica que permite fortalecer la capacidad de respuesta ante emergencias, mitigar riesgos y reducir las pérdidas asociadas a la infraestructura, la agricultura, el comercio y los servicios esenciales (Furquim et al., 2018). Dichos sistemas incorporan tecnologías que posibilitan la predicción temprana de eventos adversos mediante el uso de sensores, redes inalámbricas y algoritmos de inteligencia artificial (IA), los cuales pueden ser empleados por gobiernos y organizaciones en la toma de decisiones orientadas a proteger la seguridad de la población y los activos estratégicos, como carreteras, puentes, redes eléctricas o sistemas de abastecimiento de agua (Mowll et al., 2024; Poslad et al., 2015). Tradicionalmente, las herramientas de detección empleadas con fines de monitoreo frente a desastres naturales eran de operación manual o semiautomática, lo que implicaba costos elevados de implementación y mantenimiento (Furquim et al., 2018). Posteriormente, el desarrollo de dispositivos electrónicos y sistemas ópticos como LiDAR (Light Detection and Ranging) permitió una mayor automatización y precisión en la medición de variables topográficas y ambientales.

Los avances recientes en aprendizaje automático y aprendizaje profundo (machine learning y deep learning) han permitido una evolución notable en la detección automatizada de desastres. Modelos basados en redes neuronales convolucionales (CNN), árboles de decisión y transformers visuales se han aplicado con éxito en la identificación de incendios forestales (Boroujeni et al., 2024), inundaciones (Rahnemoonfar et al., 2021) y deslizamientos de tierra (Ghorbanzadeh et al., 2019). Además, la integración de estas técnicas con sistemas IoT ha demostrado ser eficaz para generar alertas tempranas de terremotos o tormentas mediante el procesamiento distribuido de señales sísmicas o atmosféricas (Zambrano et al., 2017).

Por otra parte, el uso de la teledetección y los vehículos aéreos no tripulados (UAVs) ha optimizado el monitoreo ambiental posterior a los desastres, permitiendo una evaluación más rápida y precisa de daños, deforestación o erosión del suelo (Lelis et al., 2024). Estos avances tecnológicos reducen los costos de reconstrucción y facilitan la implementación de políticas públicas basadas en evidencia científica (H. Sun et al., 2021).

En síntesis, la convergencia entre la inteligencia artificial, la teledetección y el Internet de las cosas constituye el eje central de la nueva generación de sistemas de detección y mitigación de desastres naturales. Esta revisión sistemática de la literatura (RSL) analiza los estudios publicados entre 2018 y 2024 para identificar las principales herramientas tecnológicas basadas en IA aplicadas a la detección de desastres naturales, así como los desafíos y oportunidades que orientan la investigación futura en este campo.

2. REVISIÓN SISTEMÁTICA DE LA LITERATURA BASADA EN LA METODOLOGÍA PRISMA

La presente revisión sistemática de la literatura se desarrolló siguiendo la metodología PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), ampliamente utilizada para garantizar la transparencia, reproducibilidad y rigor metodológico en la elaboración de revisiones sistemáticas y metaanálisis (Moher et al., 2009; Page et al., 2021).

El enfoque PRISMA establece una secuencia estructurada de fases que permiten identificar, seleccionar, evaluar y sintetizar la evidencia científica relevante, reduciendo el sesgo y mejorando la validez de los resultados (Liberati et al., 2009; Page et al., 2021). Diversos estudios recientes sobre inteligencia artificial aplicada a la gestión de desastres naturales han adoptado este enfoque para consolidar la evidencia disponible y analizar tendencias tecnológicas (T. A. Khan et al., 2020; Moreno et al., 2020).

Con el fin de alcanzar los objetivos establecidos, esta revisión se desarrolló en las siguientes etapas metodológicas:

(a) Formulación de preguntas de investigación, orientadas a identificar el alcance, las herramientas tecnológicas y las técnicas de IA aplicadas a la detección de desastres naturales; (b) Identificación de las fuentes de información, seleccionando bases de datos científicas indexadas de alto impacto (Scopus, Web of Science, IEEE Xplore); (c) Diseño de la estrategia de búsqueda, mediante la combinación de palabras clave y operadores booleanos relacionados con artificial intelligence, disaster detection, early warning systems y machine learning; (d) Definición de los criterios de elegibilidad, que incluyeron la revisión de artículos publicados entre 2018 y 2024, en inglés o español, con aplicación directa a la detección o predicción de desastres naturales; y (e) Extracción y análisis de datos, realizada mediante el uso de matrices comparativas para clasificar las técnicas, arquitecturas, métricas de evaluación y principales hallazgos.

Este procedimiento permitió obtener un panorama integral y actualizado de las tendencias en la investigación contemporánea, garantizando la trazabilidad de cada decisión metodológica conforme a los estándares internacionales de revisión sistemática.

2.1 Preguntas de investigación

En esta etapa se delimita el alcance de la revisión sistemática para garantizar un enfoque estructurado. A partir de esto, se formularon seis preguntas de investigación (Tabla 1) y se encontraron respuestas relevantes: (RQ1) ¿Qué tipo de desastres naturales son abordados para su detección usando inteligencia artificial? (RQ2) ¿Qué tecnologías asociadas al hardware y sensores son usadas? (RQ3) ¿Qué modelos, métodos y algoritmos de IA son usados? (RQ4) ¿Las técnicas utilizadas en el artículo presentan un alto rendimiento y son adecuadas para su implementación en entornos reales de gestión de desastres naturales?, (RQ5) ¿Cuáles son las principales limitaciones técnicas, éticas y prácticas del uso de IA en este campo? y finalmente (RQ6) ¿Qué tendencias emergentes se observan en el uso de IA para detección de desastres naturales?

Estas preguntas han sido establecidas para lograr presentar una revisión sistemática de la literatura de los métodos de IA que se utilizan en detección de desastres naturales.

Tabla 1. Preguntas de investigación.

N°	Preguntas de investigación	Motivación
RQ1	¿Qué tipo de desastres naturales son abordados por la inteligencia artificial?	Orientar a los investigadores en el área de inteligencia artificial a proponer novedosas soluciones de acuerdo al tipo de desastre natural identificando brechas desafíos y

		oportunidades que surgen en este campo.
RQ2	¿Qué tecnologías asociadas al hardware y sensores son usadas?	Conocer los componentes físicos y dispositivos tecnológicos que en conjunto con la inteligencia artificial (IA), permiten la detección de desastres naturales.
RQ3	¿Qué modelos, métodos y algoritmos de IA son usados?	Identificar los algoritmos más reconocidos en el ámbito académico para que los implementadores adopten buenas prácticas y desarrollen sistemas de detección más efectivos, confiables y robustos.
RQ4	¿Las técnicas utilizadas en el artículo presentan un alto rendimiento y son adecuadas para su implementación en entornos reales de gestión de desastres naturales?	Identificar los parámetros estadísticos de AUC (Area Under Curve), precisión, error cuadrático medio, que son el resultado de las aplicaciones de IA en uso.
RQ5	¿Cuáles son las principales limitaciones técnicas, éticas y prácticas del uso de IA en este campo?	Identificar los obstáculos técnicos, éticos y prácticos del uso de IA en desastres naturales.
RQ6	¿Qué tendencias emergentes se observan en el uso de IA para desastres naturales?	Conocer las tendencias emergentes en el uso de IA para desastres naturales, con el fin de identificar innovaciones y, anticipar desarrollos futuros.

2.2 Fuentes de información

Se ha realizado una revisión bibliográfica, compilando publicaciones de tres bases de datos especializadas: IEEE, Scopus y, Web Of Science (WoS) sobre la detección de desastres naturales usando inteligencia artificial. Para la búsqueda de publicaciones se aplica un filtro para seleccionar estudios posteriores al año 2017. La consulta de búsqueda utilizada: "NATURAL HAZARD DETECTION". La búsqueda se realizó el día 13/01/2025, la misma que se ejecutó para las 3 bases de datos, los filtros aplicados para todas las búsquedas fueron idioma: inglés; tipo de documentos: artículos de acceso abierto, en áreas: tierra, desastres naturales e inteligencia artificial. El string de búsqueda fue:

Tabla 2. Búsqueda específica de artículos y cantidad de resultados

Base de datos	String de búsqueda	Cantidad de resultados
SCOPUS	TITLE-ABS-KEY (("artificial intelligence" OR "computational intelligence") AND (natural OR environment) AND (hazard OR risk OR disaster))AND (LIMIT-TO (SUBJAREA , "ENVI") OR LIMIT-TO (SUBJAREA , "EART")) AND (LIMIT-TO (PUBYEAR , 2024) OR LIMIT-TO (PUBYEAR , 2023) OR LIMIT-TO (PUBYEAR , 2022) OR LIMIT-TO (PUBYEAR , 2021) OR LIMIT-TO (PUBYEAR , 2020) OR LIMIT-TO (PUBYEAR , 2019) OR LIMIT-TO (PUBYEAR , 2018)) AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "re")).	1211
Web of Science	(((((TS=(earth)) AND TS=(natural hazard)) AND TS=(artificial intelligence)) AND PY=(2018- 2024)) AND DT=(Article)) AND LA=(English)	8
IEEE	("All Metadata":natural disaster) AND ("All Metadata":artificial intelligence)	262

2.3 Selección de Artículos

En esta sección, se presenta un enfoque sistemático para seleccionar las fuentes bibliográficas más importantes. El diseño de los términos de búsqueda, así como los criterios de inclusión y exclusión se basan en las recomendaciones de (Page et al., 2021). El diagrama de flujo PRISMA (Figura 1), representa gráficamente el proceso de selección de los artículos. Este diagrama parte de los documentos identificados en la sección anterior (1481) y los va filtrando de acuerdo con los criterios de inclusión y exclusión establecidos.




Figura 1. Estrategia de búsqueda bibliográfica sobre sistemas de detección de desastres (metodología PRISMA).

En la primera exclusión se eliminaron los artículos repetidos. Seguidamente, se procedió a realizar una revisión sistemática por Título y por Abstract aplicando los siguientes criterios de exclusión técnica:

Criterio C1: Se excluyeron todos los documentos cuyo título no hiciera referencia explícita al uso de inteligencia artificial (IA) en el contexto de desastres naturales, es decir, aquellos que no mencionaran directamente tecnologías como redes neuronales, machine learning, modelos predictivos basados en IA, u otros algoritmos inteligentes aplicados a eventos como inundaciones, terremotos, incendios forestales, entre otros.

Criterio C2: Se analizaron los resúmenes (abstracts) y se descartaron aquellos que, aunque mencionaran temas ambientales o climáticos, no abordaran específicamente la aplicación de técnicas de IA en la detección, predicción o gestión de desastres naturales.

Solo los documentos que cumplieron simultáneamente con ambos criterios (C1 y C2) fueron seleccionados para la fase de análisis detallado, asegurando así la relevancia temática y metodológica en el marco de la investigación.

En la etapa de elegibilidad se establecieron criterios de exclusión basados en el contenido completo del artículo, aplicados durante la fase de lectura detallada. Los criterios fueron los siguientes:

CE1: El artículo debía tratar explícitamente la aplicación de inteligencia artificial (IA) en el contexto de desastres naturales, incluyendo tareas como predicción, detección, clasificación o respuesta ante eventos como inundaciones, terremotos, incendios forestales, deslizamientos, entre otros.

CE2: El artículo debía incluir la implementación o integración de hardware o sensores físicos en combinación con técnicas de IA, como parte de un sistema de monitoreo, alerta temprana, toma de decisiones autónoma, o control en campo.

Solo aquellos artículos que cumplieron el criterio CE1 y el CE2 fueron considerados válidos para el estudio. Como resultado, se seleccionaron 67 artículos de un total de 79 revisados, garantizando así un enfoque centrado en soluciones tecnológicas con implementación práctica en el entorno de desastres naturales.

2.4 Extracción de datos

De la búsqueda inicial con los términos "Natural Hazard detection" se identificaron un total de 1481 artículos a través de las bases de datos, eliminados por duplicidad 190, quedaron 1292 artículos. Después de la revisión de títulos y abstract se obtuvieron 79 artículos y finalmente se aplicaron criterios de exclusión como: solo deben ser artículos, deben ser artículos de acceso abierto y en el idioma inglés, dando como resultado 67 artículos, por último, se aplicaron preguntas de calidad a los artículos, con preguntas como: ¿Los resultados incluyen métricas claras y verificables?, ¿Las conclusiones están respaldadas por los resultados obtenidos?, ¿El estudio aporta una contribución original o significativa?, para ello se utilizó la herramienta Parsifal, quedando solo 52 seleccionados sistemáticamente.

3. RESULTADOS

Tras una revisión preliminar de los 52 artículos seleccionados, se identificó que la mayoría de ellos referencian el uso de algoritmos de inteligencia artificial (IA), destacando arquitecturas como redes neuronales convolucionales (CNN), máquinas de vectores de soporte (SVM) y otras variantes de aprendizaje automático supervisado. A partir de esta lectura inicial, se formularon cuatro preguntas clave para caracterizar técnicamente el enfoque de cada artículo:

P1. ¿Qué tecnologías complementarias a la inteligencia artificial se emplean en el artículo?

Se identificó que varios estudios combinan el uso de IA con otras tecnologías complementarias. Los recuentos resumidos en la Tabla 3 evidencian una tendencia creciente hacia la integración de la IA con otras plataformas de adquisición y análisis masivo de datos, lo que refleja el avance en el desarrollo de sistemas más eficientes para la detección y gestión de desastres naturales.

Tabla 3. Tecnologías que complementan la Inteligencia artificial.

Tecnologías - IA	Cantidad
Big data	31
Visión computacional	16
Internet de las cosas (IoT)	3
chatGPT u otros modelos de lenguaje generativo	1
Redes sociales como fuente de datos	1

Total	52
-------	----

P2. ¿Qué tipo de algoritmos de inteligencia artificial son mencionados o utilizados?

Del total de estudios analizados, 32 artículos describen explícitamente la implementación y aplicación de algoritmos IA, incluyendo arquitecturas como máquinas de soporte vectorial (SVM), redes neuronales del tipo LSTM (Long Short-Term Memory), redes neuronales artificiales (ANN), regresión logística (LR), redes neuronales convolucionales CNN (Convolutional Neural Networks), y YOLO (You Only Look Once), entre otros. Estos algoritmos se emplean principalmente en tareas de clasificación, detección y predicción. Por otro lado, 20 artículos hacen referencia a la IA de manera general, sin especificar o implementar algoritmos específicos dentro de sus metodologías. Los resultados de esta clasificación se presentan en la Tabla 4 y Figura 2, la cual permite visualizar las arquitecturas de IA más empleadas y su relación con las tecnologías de soporte utilizadas.




Figura 2. Tipo de algoritmos y clasificadores de Inteligencia Artificial

Tabla 4. Algoritmos de IA aplicadas.

Algoritmos IA	Cantidad
Máquinas de soporte vectorial (SVM)	7
Bosque aleatorio (RF), Redes neuronales LSTM	5
Árboles de decisión (DT)	4
Redes neuronales artificiales (ANN), Shapley Additive Explanations (SHAP)	3
Aprendizaje profundo (DL), LightGBM, Red neuronal convolucional (CNN), Aprendizaje profundo (Deep Learning), Red neuronal YOLO, U-Net, K-nearest neighbour (KNN)	2
Modelo lineal generalizado (GLM), Clasificación de disparo cero (zero-shot classification), Red neuronal convolucional recurrente de múltiples grafos (SA-MGCRN), Ensamblado de aprendizaje automático (Stacking ensemble),	1

CatBoost, XGBoost, Red neuronal profunda (DNN), Bosques aleatorios ponderados geográficamente (GWRF), Red adversarial generativa recurrente (RGAN), Máquinas de soporte vectorial con optimización por enjambre de partículas (PSO-SVM), Aprendizaje por refuerzo (Reinforcement Learning), Visión por computadora, Redes neuronales recurrentes (RNN), Inteligencia artificial explicable (XAI), Transformador de visión (ViT), Red neuronal profunda, Harris Hawk Optimization (HHO), Ensamblado de modelos (Stacking), Generative AI, DeepLabV3, Regresión LASSO, CNN con aprendizaje sin olvido (LwF), Redes neuronales binarizadas, Red neuronal convolucional 1D (CNN-1D), Aprendizaje federado con optimización por enjambre de partículas (PSO-FL), ResNet-50, CNN 2D y 3D, ConvLSTM, MobileNetV2, Bagging ensemble (BE), Logistic model tree (LT), Kernel support vector machine (k-SVM), Clasificadores Boosting, Decision Jungle, Naïve Bayes (NB), Generalized Additive Model (GAM), Adaptive Neuro-Fuzzy Inference System (ANFIS), Red neuronal feed-forward optimizada por optimización de enjambre de partículas (PSO), Autoencoders profundos, Inteligencia de fuentes abiertas (OSINT), Regresión Logística (LR)

Posteriormente a la selección de los 52 artículos incluidos en la revisión, se aplicó un criterio analítico orientado a evaluar la contribución sustantiva de cada documento al campo de la inteligencia artificial aplicada a la gestión de desastres naturales.

P3. ¿El artículo realiza aportes concretos para mejorar la gestión de desastres naturales mediante inteligencia artificial, contribuye teóricamente al desarrollo de la IA, o se limita al uso de técnicas tradicionales o revisiones? Esta pregunta permitió clasificar los documentos según el nivel y tipo de aporte técnico o metodológico. El análisis mostró que 34 artículos presentan una contribución activa al conocimiento en IA aplicada a desastres naturales, ya sea mediante:

- El desarrollo de nuevas arquitecturas o mejoras de algoritmos existentes.
- Aplicaciones prácticas integradas con sensores o entornos simulados.
- La implementación de modelos predictivos o sistemas de alerta basados en aprendizaje automático.

En contraste, 18 artículos no presentan aportes metodológicos directos; más bien se centran en:

- Revisión sistemática de la literatura.
- Clasificación y comparación de técnicas existentes.
- Aplicaciones sin innovación teórica en IA o sin evaluación empírica detallada.

Los resultados de esta evaluación permiten identificar los estudios que fortalecen directamente el avance del campo técnico de la inteligencia artificial en la gestión de desastres naturales.

Finalmente, se aplicó un criterio de evaluación enfocado en la efectividad operativa de las técnicas basadas en inteligencia artificial frente a escenarios reales de desastres naturales, mediante la siguiente pregunta:

P4. ¿Las técnicas utilizadas en el artículo presentan un alto rendimiento y son adecuadas para su implementación en entornos reales de gestión de desastres naturales?

Esta evaluación permitió determinar la viabilidad práctica de los enfoques propuestos, considerando aspectos como rendimiento bajo condiciones reales, validación en campo, resiliencia frente a fallos y compatibilidad con la infraestructura existente.

El análisis de los 52 artículos reveló que 19 artículos presentan modelos o sistemas con alta aplicabilidad práctica, caracterizados por:

- Validación con datos reales o simulaciones avanzadas.
- Desempeño robusto bajo condiciones adversas (latencia, ruido, fallos).

- Integración efectiva con sensores físicos, sistemas de comunicación o plataformas de alerta temprana.
- Por otro lado, 33 artículos ofrecen soluciones con baja aplicabilidad operacional, debido a:
- Pruebas exclusivamente teóricas o basadas en datasets simulados sin implementación práctica.
 - Ausencia de validación en campo o limitaciones técnicas (alta dependencia de conectividad o falta de tolerancia a fallos).
 - Modelos con complejidad computacional excesiva o sin análisis de escalabilidad.
- Estos resultados muestran que 19 artículos proporcionan una visión clara sobre cuáles estudios ofrecen soluciones técnicamente viables para una gestión de desastres naturales en contextos reales.

4. DISCUSIÓN

Las preguntas de investigación planteadas en este estudio fueron las siguientes:

4.1 Respuesta a RQ1: ¿Qué tipo de desastres naturales son abordados mediante inteligencia artificial (IA)?

Se realizó una clasificación de los tipos de desastres naturales abordados mediante técnicas de IA en los artículos seleccionados. Esta categorización permite identificar las áreas de mayor interés y aplicación tecnológica. Los resultados, sistematizados en la Figura 3, muestran que la investigación se concentra principalmente en eventos hidrometeorológicos, aunque comienzan a explorarse otros fenómenos menos estudiados, evidenciando un campo en expansión.



Figura 3. Desastres naturales más investigados por IA.

4.2 Respuesta a RQ2: ¿Qué tecnologías asociadas al hardware y a los sensores son utilizadas?

Se realizó un análisis técnico de las tecnologías de hardware y sensores utilizadas en los artículos seleccionados, con el fin de identificar los componentes físicos más empleados en la implementación de soluciones basadas en IA. Los resultados, presentados en la Figura 4, revelan una predominancia de satélites, drones y sensores meteorológicos.




Figura 4. Tecnologías de hardware y sensores utilizados

4.3 Respuesta a RQ3. ¿Qué modelos, métodos, algoritmos de IA son utilizados?

El análisis de las publicaciones evidenció que la Red Neuronal Convolutiva (CNN) es la arquitectura más empleada en las soluciones propuestas para la gestión de desastres naturales. Diversos estudios presentan variaciones de las CNN estándar con el objetivo de optimizar su desempeño en tareas específicas, tales como la detección de incendios forestales, el análisis de imágenes satelitales o la clasificación de eventos extremos. Las principales modificaciones identificadas incluyen:

- Ajustes en la profundidad y número de capas convolucionales.
- Incorporación de técnicas de regularización y normalización para mejorar la generalización
- Combinación con otras arquitecturas como YOLO (You Only Look Once) para tareas de detección en tiempo real.
- Implementación de aprendizaje por transferencia (transfer learning) con modelos preentrenados (p.ej., VGG16, ResNet).

Estos enfoques reflejan una tendencia hacia la especialización de modelos CNN para contextos ambientales complejos, con el objetivo de mejorar métricas de precisión, sensibilidad y tiempo de inferencia.

La Tabla 5 sintetiza los algoritmos de IA más utilizados incluyendo CNN, SVM, LSTM, ANFIS y Random Forest, proporcionando una visión cuantitativa y comparativa de las técnicas predominantes en el corpus analizado.

Tabla 5. Algoritmos de IA más utilizados.

Algoritmo IA	Artículo
ML	(Boroujeni et al., 2024) (Furquim et al., 2018) (Lelis et al., 2024) (Lee & Lee, 2024) (Ge et al., 2024) (Supriya & Gadekallu, 2023) (Yaseen et al., 2022) (Kumar & Laxmi, 2021) (Aswad et al., 2022) (Rahmati et al., 2019)

DT	(Aswad et al., 2022) (Oyoumalsoud et al., 2024) (Afrin et al., 2024) (Yu & He, 2022)
Modelo lineal generalizado (GLM), Red neuronal artificial	(Oyoumalsoud et al., 2024)
SVM	(Moreno et al., 2020) (Rahmati et al., 2019) (Oyoumalsoud et al., 2024) (Afrin et al., 2024) (Liu et al., 2023) (Pang et al., 2022) (Zhou et al., 2018)
DL	(Boroujeni et al., 2024) (Supriya & Gadekallu, 2023) (Oyoumalsoud et al., 2024) (Fayaz et al., 2024) (Costache et al., 2024) (Alan et al., 2023a) (Ball et al., 2022) (Antoniou & Potsiou, 2020)
RF	(Lee & Lee, 2024) (Yaseen et al., 2022) (Aswad et al., 2022) (Rahmati et al., 2019) (Oyoumalsoud et al., 2024) (Liu et al., 2023) (Pang et al., 2022)
CatBoost , XGBoost	(Lee & Lee, 2024)
LightGBM	(Lee & Lee, 2024) (Liu et al., 2023)
CNN	(Moreno et al., 2020) (Afrin et al., 2024) (Ball et al., 2022) (Sathishkumar et al., 2023) (Adikari et al., 2021) (Jung et al., 2020)
Regresión Lineal Múltiple (MLF)	(Afrin et al., 2024)
Red neuronal profunda (DNN), Variables latentes sustitutas (LV)	(Fayaz & Galasso, 2024)
Redes generativas adversas (GAN), Maquina de soporte de vectores de optimización de enjambre de partículas (PSO.SVM)	(Ge et al., 2024)
Redes de memoria a corto plazo (LSTM)	(Ge et al., 2024) (Fayaz et al., 2024) (Adikari et al., 2021) (Alan et al., 2023b) (lan et al., 2023) (Rosi, 2023)
Redes de comunicación de datos (DCN)	(Abdalzaher et al., 2024)
Aprendizaje por refuerzo (RL)	(Boroujeni et al., 2024)
redes neuronales recurrentes (RNN)	(Fayaz et al., 2024)
Inteligencia artificial explicable (XAI)	(Liu et al., 2023) (Fayaz et al., 2024)
Aprendizaje por transferencia	(Sathishkumar et al., 2023) (Chamatidis et al., 2024) (Wang & Brenning, 2023)
Procesamiento de lenguaje natural, Variación y transformador de visión (ViT)	(Chamatidis et al., 2024)
Explicaciones aditivas de SHAPPlay (SHAP)	(Liu et al., 2023) (Li et al., 2024) (Cilli et al., 2022)
IA generativa	(Teoh et al., 2024)
Yolo	(Teoh et al., 2024) (Abdusalomov et al., 2022)
U-net	(Gupta & Kim, 2024) (Garduño, Eduardo Ciprián-Sánchez, Jorge Vázquez-García et al., 2023)
DeepLabV3, Red de análisis de escenas piramidales	(Gupta & Kim, 2024)
Modelo de predicción del comportamiento de propagación de incendios forestales (FRSBP)	(X. Sun et al., 2024)

BALSSA	(Ilan et al., 2023)
LASSO	(Wahba et al., 2023)
VGG16, InceptionV3, Xception, Aprendizaje sin olvidar (LWF)	(Sathishkumar et al., 2023)
ChatGPT	(Xue et al., 2023)
Naive bayes (BN)	(Rahmati et al., 2019) (Liu et al., 2023)
Redes neuronales Binarizadas (BNN)	(Garduño, Eduardo Ciprián-Sánchez, Jorge Vázquez-García et al., 2023)
Aprendizaje Federado	(Supriya & Gadekallu, 2023)
RestNet-50, Arbol de Hoffding, J48, Arbol de modelo lineal (LMT), regresión logística, Bayes Net	(Seeja et al., 2023)
Percetron multicapa	(Yaseen et al., 2022) (Seeja et al., 2023)
Redes de formación de base lineal KNN	(Pang et al., 2022)
FFireNET, Mobile Net V2, Arbol de modelo lógico (LT), K-SVM,	(S. Khan & Khan, 2022)
Inferencia neuro difuso adaptativo (WANFIS)	(Moreno et al., 2020) (Adikari et al., 2021)
FlooNet	(Rahnemoonfar et al., 2021)
Decision Jungle	(Aswad et al., 2022)
Modelo adaptativo generado (GAM)	(Rahmati et al., 2019)
Algoritmo de optimización de enjambre de partículas	(T. A. Khan et al., 2020)
Red neuronal artificial (ANN)	(Zhou et al., 2018)

4.4 Respuesta a RQ4. ¿Las técnicas utilizadas en el artículo presentan un alto rendimiento y son adecuadas para su implementación en entornos reales de gestión de desastres naturales?

Se identificó la tendencia del rendimiento entre algoritmos, a partir de los valores del área bajo la curva (AUC) como métrica de evaluación extraídos de los estudios analizados en la revisión sistemática. Los resultados (ver Figura 5) indican que:

- En el estudio de susceptibilidad a deslizamientos obtuvieron un AUC de 0.89 (0.891 en la clasificación general y 0.89 para deslizamientos de gran magnitud) (Lee & Lee, 2024).
- En el estudio sobre la ocurrencia de incendios forestales, la revisión encontró valores de AUC de 0.94, validando su alta fiabilidad (Li et al., 2024).
- Los modelos aplicados a la predicción de deslizamientos de tierra alcanzaron a AUC promedio más alta (0.9936), evidenciando excelente capacidad de discriminación en la identificación de condiciones de riesgo geotécnico (Wahba et al., 2023).
- Los algoritmos utilizados para el análisis y predicción de inundaciones mostraron también alto rendimiento (AUC promedio del 0.9906), destacando el uso de redes neuronales optimizadas y técnicas híbridas como ANN-PSO y LSTM (Wahba et al., 2023). Aplicando la técnica de validación cruzada se obtuvieron valores de AUC de 0.97 para modelos de Bagging Ensemble y Logistic Tree (Al-Areeq et al., 2022).
- De forma global, Random Forest (RF) obtuvo el mejor desempeño general (AUC promedio de 0.964) en diversas funciones como clasificación de zonas de riesgo, predicción de eventos y análisis multiclase. Su robustez frente al ruido de datos, bajo sobreajuste y capacidad de interpretación lo posicionan como una técnica altamente efectiva y confiable (Rahmati et al., 2019).



Figura 5. Índice AUC de aplicaciones IA.

Se realizó un análisis comparativo del desempeño de precisión de las técnicas de inteligencia artificial implementadas en los artículos revisados, considerando su aplicación específica en distintos componentes de la gestión de desastres naturales. Los resultados evidencian diferencias en el rendimiento de los modelos en función de su propósito operativo y del tipo de datos procesados.

- Las IA utilizadas en sistemas de apoyo a la toma de decisiones en contextos de emergencia registran los niveles de precisión más altos, con un promedio del 99.8%, demostrando su alta efectividad en la priorización de acciones críticas y la gestión operativa basada en análisis automatizado de datos.
- En segundo lugar, los modelos orientados a la clasificación de víctimas en escenarios de desastre alcanzaron una precisión promedio del 99.53%, aplicando técnicas como Máquinas de Soporte Vectorial (SVM) y redes neuronales artificiales (ANN) para el procesamiento de datos clínicos o contextuales, facilitando así procesos de triaje automatizado.
- Las IA empleadas en la clasificación de eventos de inundación, tales como la identificación de zonas afectadas o la estimación de niveles de severidad también presentaron un desempeño (99%), principalmente mediante arquitecturas CNN y Random Forest, aplicadas al análisis de imágenes satelitales y flujos hídricos.

En contraste, las técnicas de detección directa de inundaciones en tiempo real mostraron un desempeño significativamente menor, con una precisión promedio del 84.84%. Este resultado sugiere la existencia de limitaciones técnicas asociadas a la baja resolución de sensores, la latencia en la transmisión de datos, y las condiciones ambientales adversas que afectan la fiabilidad del modelo en escenarios reales.

En conjunto, este análisis destaca la variabilidad del rendimiento de la IA según su aplicación específica y refuerza la importancia de evaluaciones contextualizadas y funcionales al seleccionar algoritmos para la gestión de desastres. Los resultados consolidados se ilustran de forma comparativa en la Figura 6.




Figura 6. precisión de aplicaciones de IA para la detección de desastres naturales.

4.5 Respuesta a RQ5. ¿Cuáles son las principales limitaciones técnicas, éticas y prácticas del uso de IA en este campo?

El análisis de los estudios revisados permitió identificar un conjunto de limitaciones técnicas, éticas y operativas que obstaculizan la implementación efectiva de sistemas basados en inteligencia artificial (IA) para la gestión de desastres naturales.

Una de las principales barreras técnicas reportadas en diversos estudios (artículos (Moreno et al., 2020), (Chamatidis et al., 2024), (Adikari et al., 2021), y (Abdalzaher et al., 2023)), está relacionada con la calidad, integridad y resolución de los datos. Los modelos de IA dependen de series temporales densas, multivariadas y consistentes; sin embargo, este tipo de información es escasa en regiones vulnerables donde la infraestructura de sensores es limitada o inestable. Por ejemplo, en el artículo (Chamatidis et al., 2024) señala que la pérdida de paquetes en redes de sensores puede provocar fallos en la inferencia de modelos de inundación súbita, incluso cuando se emplean arquitecturas optimizadas mediante Particle Swarm Optimization (PSO).

Otra limitación técnica relevante corresponde a la alta sensibilidad de los modelos a los hiperparámetros y al riesgo de sobreajuste, particularmente en escenarios de aprendizaje supervisado con conjunto de datos desbalanceados o limitados. Según el artículo (Moreno et al., 2020), las redes LSTM, aunque potentes, requieren un cuidadoso preprocesamiento y validación cruzada para evitar la detección de patrones espurios, sobre todo en datos de caudales irregulares y ríos con estacionalidades abruptas. A ello se suma la falta de interoperabilidad entre modelos IA y plataformas de monitoreo tradicionales, lo que dificulta su integración en infraestructuras de alerta temprana existentes.

Desde el punto de vista ética, se advierte sobre la opacidad de los modelos de IA y su limitada capacidad de auditoría por parte de operadores humanos o comunidades vulnerables (Afrin et al., 2024). Aunque se han desarrollado esfuerzos hacia una IA explicable (XAI) como el uso de enfoques híbridos basados en Random Forest ponderado geográficamente (GWR-RF), persiste el riesgo de que decisiones críticas (por ejemplo, declaración de evacuaciones) se basen en modelos no interpretables por usuarios no técnicos, comprometiendo la transparencia y la rendición de cuentas.

Asimismo, el uso de información extraída de redes sociales o sensores (IoT) personales plantea preocupaciones respecto a la privacidad y el consentimiento informado. En el artículo (Ghorbanzadeh et al., 2019), por ejemplo, se analiza el empleo de datos textuales espontáneos para la clasificación de eventos en tiempo real, sin detallar protocolos de anonimización o consentimiento informado. Esto evidencia una tensión

entre la necesidad de inmediatez en la respuesta a emergencias y la protección a los derechos individuales, especialmente en contextos de vigilancia ubicua o gobiernos autoritarios.

En el plano práctico, varios trabajos ((Abdalzaher et al., 2023), (Adikari et al., 2021), (Chamatidis et al., 2024)) destacan la dificultad de trasladar los modelos IA desde ambientes simulados hacia condiciones reales de operación, debido a factores como la variabilidad ambiental, pérdida de conectividad, las interferencias electromagnéticas y las limitaciones energéticas de los dispositivos de borde. El sistema SENDI, descrito en el artículo (Abdalzaher et al., 2023), demuestra una adecuada tolerancia a fallos en entornos simulados; sin embargo, su despliegue real implica costos elevados, mantenimiento y procesos de calibración complejos, aspecto que muchas regiones en riesgo no están en capacidad de asumir.

Además, se identificó una dependencia crítica de las infraestructuras eléctrica y de telecomunicaciones, lo cual limita la operatividad de los modelos IA durante el propio desastre (por ejemplo, blackouts o cortes de fibra óptica). En estos escenarios, sensores distribuidos con IA embebida (Edge AI) pueden volverse inoperantes ante eventos sísmicos o meteorológicos extremos si no cuentan con fuentes de energía de respaldo.

Finalmente, se evidencian barreras institucionales y culturales que dificultan la adopción de tecnologías basadas en IA. En diversas regiones en desarrollo, las decisiones en gestión del riesgo continúan sustentándose en métodos empíricos o en la experiencia de expertos humanos, mientras que persiste una desconfianza general hacia los sistemas automatizados. Esta resistencia se refuerza cuando los modelos no ofrecen explicaciones claras de sus predicciones o no incorporan el conocimiento local, como los mapas de evacuación comunitarios.

4.6 Respuesta a RQ6. ¿Qué tendencias emergentes se observan en el uso del IA para la gestión de desastres naturales?

Los estudios analizados ((Moreno et al., 2020), (Chamatidis et al., 2024)) evidencian una tendencia creciente hacia el desarrollo de modelos híbridos que combinan redes neuronales artificiales (ANN) con algoritmos de optimización evolutiva, tales como Particle Swarm Optimization (PSO) y Cuckoo Search. Estas técnicas se utilizan para optimizar hiperparámetros críticos como el número de capas ocultas, las tasas de aprendizaje y las estructuras de entrada. Por ejemplo, el artículo (Chamatidis et al., 2024) implementó una red neuronal feed-forward optimizada con PSO para la predicción de inundaciones relámpago, logrando reducir significativamente la tasa de falsas alarmas en comparación con algoritmos tradicionales. Estos sistemas fueron entrenados con datos multiresolución provenientes de sensores de nivel de agua, infrarrojos pasivos, ultrasónicos y de presión, lo cual demuestra la necesidad de modelos de IA no sólo precisos, sino también robustos frente al ruido y adaptables en tiempo real.

La aplicación de modelos basados en LSTM (Long Short-Term Memory) y NNARX (Nonlinear Autoregressive Models with Exogenous Inputs) se ha vuelto cada vez más frecuente en la predicción de caudales y precipitaciones en ríos vulnerables ((Moreno et al., 2020) y (Adikari et al., 2021)). Estas redes son capaces de capturar dependencias de largo plazo en datos de series temporales no lineales, incorporando variables exógenas como volumen de lluvia, niveles históricos de caudal y temperatura. En el caso del río Kelantan (Adikari et al., 2021), una LSTM entrenada con secuencias históricas alcanzó una elevada precisión en predicciones a seis horas, incluso durante eventos extremos. Este tipo de avances refleja la transición desde modelos estáticos hacia arquitecturas dinámicas con memoria contextual, fundamentales para la anticipación y gestión del riesgo.

Un aspecto técnico emergente es la adopción de modelos de IA explicable (XAI), especialmente Random Forests ponderados geográficamente (GWR-RF) descritos en (Afrin et al., 2024). Este enfoque integra el aprendizaje automático con modelos de regresión localmente adaptativos, permitiendo que las predicciones de eventos sísmicos o climáticos extremos puedan ser interpretables por los operadores humanos. Su principal ventaja radica en la capacidad de asignar pesos espaciales a cada variable predictora, aspecto crítico en la predicción de terremotos o deslizamientos, donde la variabilidad geográfica incide directamente en la fiabilidad

del modelo. En consecuencia, estos sistemas fortalecen la confianza operacional y la transparencia en la toma de decisiones críticas.

Asimismo, el artículo (Chamatidis et al., 2024) introduce arquitecturas que integran inteligencia artificial en nodos distribuidos de sensores, utilizando protocolos como ZigBee y simulaciones en entornos como NS-3. Esta tendencia apunta al desarrollo de sistemas de alerta temprana resilientes a fallas de comunicación o energía, capaces de operar de manera descentralizada. Desde un punto de vista técnico, este enfoque implica que los modelos de IA no se ejecutan únicamente en servidores centrales, sino directamente en los sensores físicos mediante procesamiento en el borde (Edge Computing), reduciendo la latencia y aumentando la tolerancia a fallas durante emergencias.

Otra tendencia clave es el uso de múltiples tipos de sensores con fusión de datos mediante IA, evidenciada en (Chamatidis et al., 2024). En este caso, se emplean sensores de distinta naturaleza PIR, ultrasónicos, altímetros, de presión y temperatura cuyas salidas se integran mediante redes neuronales optimizadas para minimizar la redundancia y maximizar la fiabilidad. Este enfoque multirresolución incrementa la sensibilidad del sistema ante variaciones abruptas de las variables físicas, resultando ideal para la detección temprana de inundaciones súbitas y la reducción de falsos positivos. Además, el uso de algoritmos de fusión jerárquica permite adaptar los modelos a distintos escenarios físicos con distintas topologías y tipos de flujo.

Por otro lado, el artículo (Ghorbanzadeh et al., 2019) presenta un enfoque de aprendizaje supervisado, específicamente Random Forest, para clasificar mensajes en redes sociales en 13 categorías de emergencias naturales. Este modelo permite identificar automáticamente la naturaleza del evento (inundación, incendio, deslizamiento, etc.) y mejorar la coordinación de recursos en tiempo real. Este enfoque aprovecha técnicas de preprocesamiento lingüístico y vectorización textual (TF-IDF y embeddings) para alimentar el modelo, destacando la versatilidad de la IA para integrar datos físicos o meteorológicos, hacia el análisis de información textual espontánea con fines de respuesta inmediata.

Finalmente, en el caso del río Magdalena ((Moreno et al., 2020)), se empleó ANFIS (Adaptive Neuro-Fuzzy Inference System) como alternativa a las redes neuronales estándar. Esta técnica combina la capacidad de aprendizaje de las ANN con la interpretación semántica de los sistemas difusos, permitiendo generar reglas explícitas sobre condiciones de alerta. ANFIS, basado en una estructura de cinco capas y reglas de inferencia tipo Takagi-Sugeno, proporciona un balance entre precisión y explicabilidad, aspecto crucial cuando se requiere que el modelo sea auditado por autoridades o comunidades locales.

5. DESAFÍOS ABIERTOS EN IA Y DESASTRES NATURALES

5.1 Desafíos en Machine Learning y Deep Learning

La implementación efectiva de Machine Learning y Deep Learning en la gestión de desastres naturales enfrenta una serie de desafíos que deben resolverse para lograr aplicaciones operativas en entornos reales. Si bien la naturaleza de los retos varía según el tipo de desastre, por ejemplo, en el caso de las sequías, donde intervienen factores climáticos, oceánicos y atmosféricos, existen problemáticas comunes vinculadas a la extracción de características, la alta dimensionalidad de los datos, métodos de reducción, la disponibilidad de información confiable y la precisión de algoritmos de Machine Learning.

5.2 Desafíos en Sistemas de Información Geográfica (GIS)

La integración de Sistemas de Información Geográfica (GIS) con técnicas de Machine Learning (ML) y Deep Learning (DL) ofrece un potencial considerable para la gestión de desastres naturales. Sin embargo, su implementación enfrenta desafíos técnicos que deben ser abordados para garantizar resultados robustos, confiables y operativos en escenarios reales.

Otro desafío crítico es la extracción automática de características relevantes a partir de datos complejos y

multivariados (ej., satelitales, meteorológicos, hidrológicos), especialmente en desastres como sequías, donde interactúan variables climáticas, oceánicas y atmosféricas de alta incertidumbre. En estos casos, la capacidad de los modelos para seleccionar patrones útiles sin introducir ruido es clave para su rendimiento.

La alta dimensionalidad de los datos constituye otro obstáculo relevante, ya que puede afectar la generalización del modelo y provocar sobreajuste. Para mitigar este problema, se requiere la aplicación de técnicas eficientes de reducción de dimensionalidad (como PCA, t-SNE o autoencoders), lo cual implica un balance entre mantener información esencial y reducir la carga computacional.

Asimismo, la disponibilidad limitada y heterogénea de datos en muchas regiones vulnerables representa una barrera estructural para el uso de GIS en contextos de emergencia. Los modelos avanzados como redes neuronales profundas que dependen de grandes volúmenes de datos etiquetados y balanceados, enfrentan dificultades cuando la información es escasa o incompleta, lo que restringe su aplicabilidad operacional en tiempo real.

Finalmente, la precisión y estabilidad de los algoritmos es aún un reto en dominios con alta variabilidad ambiental. Factores como ruido en los sensores, lag temporal, o datos faltantes afectan directamente la fiabilidad del modelo y dificultan su implementación operativa.

En conjunto, estos desafíos requieren no solo mejoras algorítmicas, sino también estrategias de preprocesamiento de datos, integración multisensorial y calibración dinámica, especialmente adaptadas al tipo de desastre que se desea gestionar.

5.3 Desafíos de la robótica en Desastres Naturales

La robótica constituye una de las tecnologías emergentes clave en los sistemas de alerta y respuesta ante desastres naturales, especialmente en tareas de búsqueda, rescate y reconocimiento en entornos peligrosos o de difícil acceso. Sin embargo, su implementación efectiva enfrenta aún varios desafíos técnicos y operativos relevantes.

Entre los retos más destacados se encuentra el desarrollo de sistemas de enjambre robótico, donde múltiples robots colaboran de manera coordinada bajo condiciones extremas. Este tipo de despliegue requiere algoritmos avanzados de control distribuido, comunicación entre agentes, asignación dinámica de tareas y adaptación en tiempo real frente a cambios impredecibles en el entorno (ej., estructuras colapsadas, obstáculos móviles).

Otro desafío crítico es la simulación realista de escenarios de rescate, como la disposición aleatoria de víctimas o el incremento controlado del número de objetivos (víctimas) dentro del entorno. Estas simulaciones son esenciales para evaluar y mejorar los algoritmos de planificación, búsqueda y navegación utilizados por los robots.

En particular, se pone a prueba la capacidad de los modelos basados en Procesos de Decisión Parcialmente Observables (POMDP), los cuales permiten a los robots tomar decisiones bajo incertidumbre cuando el conocimiento del entorno es incompleto. Aumentar la complejidad del entorno, por ejemplo, con múltiples víctimas o información incompleta permite identificar los límites computacionales y operativos de estos solucionadores, y orientar su optimización para aplicaciones reales.

El abordaje de estos desafíos implica combinar avances en robótica autónoma, inteligencia artificial distribuida y simulación de ambientes extremos, con el objetivo de diseñar sistemas de asistencia robótica más resilientes, precisos y eficaces en contextos de desastre natural.

5.4 Tecnologías Consolidadas

El avance continuo de la inteligencia artificial (IA) ha impulsado una evolución significativa en los algoritmos aplicados a la gestión de desastres naturales, permitiendo el desarrollo de soluciones cada vez más especializadas y efectivas. En varios tipos de desastres, ciertas tecnologías ya pueden considerarse consolidadas debido a su alta precisión y madurez técnica.

Un caso destacado es la detección temprana de incendios forestales, donde algoritmos como SFEWAN-SD han alcanzado niveles de precisión del 94% en la identificación de focos activos. Al integrarse con sistemas de Big Data y sistemas de ciudades inteligentes, permiten una detección temprana en entornos urbanos con una tasa de acierto de hasta 91%, gracias al uso de sistemas de soporte a la decisión y análisis en tiempo real. En el caso de la predicción de deslizamientos de tierra inducidos por lluvias, se ha identificado un alto grado de madurez técnica. Algoritmos como Decision Tree y Random Forest muestran precisiones superiores al 93%, basándose en variables geotécnicas, hidrológicas y meteorológicas. Estos modelos han demostrado eficacia tanto en simulaciones como en aplicaciones de campo, particularmente en regiones montañosas y de alta pendiente.

Otro campo tecnológico avanzado es la clasificación automática de desastres mediante análisis de video, donde el uso de Deep Learning en conjunto con Support Vector Machines (SVM) ha permitido una identificación eficiente de eventos como incendios, inundaciones y colapsos estructurales en tiempo real, utilizando imágenes aéreas, drones o cámaras urbanas.

Además, se ha documentado el uso creciente de redes sociales como fuente de información no estructurada para la detección de desastres, mediante algoritmos de IA que procesan texto, imágenes y geolocalización. Estas técnicas han alcanzado una precisión promedio del 88%, facilitando una respuesta temprana basada en publicaciones de usuarios durante emergencias, aunque aún enfrentan desafíos en veracidad y ambigüedad del lenguaje natural.

En conjunto, estos resultados reflejan una madurez tecnológica progresiva en áreas específicas, y confirman que la combinación de IA con Big Data, visión computacional, sensores y plataformas ciudadanas puede formar un ecosistema robusto para la gestión inteligente de desastres naturales.

6. CONCLUSIÓN

En este estudio se llevó a cabo una revisión sistemática de literatura científica enfocada en la aplicación de inteligencia artificial (IA) en el contexto de la gestión de desastres naturales. El proceso metodológico incluyó una búsqueda estructurada, una evaluación crítica y un análisis comparativo de publicaciones académicas que abordan esta temática desde distintas perspectivas técnicas y operativas.

Para asegurar la calidad y relevancia científica de las fuentes, la búsqueda se restringió a bases de datos internacionales de alto impacto, incluyendo Scopus, IEEE Xplore y Web of Science (WoS). Estas plataformas garantizan el acceso a publicaciones revisadas por pares, con enfoque en ingeniería, ciencia de datos, informática aplicada y gestión de riesgos de desastres, lo que permitió construir un corpus de artículos con alto rigor técnico y metodológico.

La revisión permitió identificar las principales tecnologías, arquitecturas y algoritmos de IA, así como clasificar los enfoques según el tipo de desastre abordado, el modelo de IA empleado, su grado de integración con hardware y sensores y el nivel de madurez tecnológica alcanzado. Asimismo, se evaluó la viabilidad práctica de los sistemas propuestos en entornos operacionales reales, contribuyendo a delinear oportunidades futuras de investigación en la aplicación de IA para la gestión inteligente de desastres naturales.

La visión artificial se ha convertido en un pilar fundamental en la detección, el mapeo y la gestión de riesgos de avalanchas, ofreciendo mejoras sustanciales en precisión, escalabilidad y eficiencia operativa. Si bien los modelos de aprendizaje profundo y aprendizaje automático han demostrado un alto rendimiento, es necesario abordar desafíos constantes como el desequilibrio de clases, la calidad de los datos y la generalización para

alcanzar su máximo potencial en diversos entornos del mundo real.

La inteligencia artificial está revolucionando la gestión de desastres naturales, mejorando la predicción, respuesta y resiliencia. Sin embargo, persisten desafíos en datos, interpretabilidad, equidad y colaboración, que deben abordarse para maximizar su impacto.

Financiación

Esta investigación no recibió financiación externa.

Conflictos de interés: Los autores declaran no tener ningún conflicto de interés.

REFERENCIAS

- Abdalzاهر, M. S., Krichen, M., & Falcone, F. (2024). Emerging technologies and supporting tools for earthquake disaster management: A perspective, challenges, and future directions. *Progress in Disaster Science*, 23, 100347. <https://doi.org/10.1016/j.pdisas.2024.100347>
- Abdusalomov, A. B., Mukhiddinov, M., Kutlimuratov, A., & Whangbo, T. K. (2022). Improved Real-Time Fire Warning System Based on Advanced Technologies for Visually Impaired People. In *Sensors* (Vol. 22, Issue 19). <https://doi.org/10.3390/s22197305>
- Adikari, K. E., Shrestha, S., Ratnayake, D. T., Budhathoki, A., Mohanasundaram, S., & Dailey, M. N. (2021). Evaluation of artificial intelligence models for flood and drought forecasting in arid and tropical regions. *Environmental Modelling & Software*, 144, 105136. <https://doi.org/10.1016/j.envsoft.2021.105136>
- Afrin, N., Ahamed, F., & Rahman, A. (2024). Development of a convolutional neural network based regional flood frequency analysis model for South-east Australia. *Natural Hazards*, 120(12), 11349–11376. <https://doi.org/10.1007/s11069-024-06669-z>
- Alan, A. R., Bayındır, C., Ozaydin, F., & Altıntaş, A. A. (2023a). The Predictability of the 30 October 2020 İzmir-Samos Tsunami Hydrodynamics and Enhancement of Its Early Warning Time by LSTM Deep Learning Network. In *Water*, 15 (23), 4195. <https://doi.org/10.3390/w15234195>
- Al-Areeq, A. M., Abba, S. I., Yassin, M. A., Benaafi, M., Ghaleb, M., & Aljundi, I. H. (2022). Computational Machine Learning Approach for Flood Susceptibility Assessment Integrated with Remote Sensing and GIS Techniques from Jeddah, Saudi Arabia. *Remote Sensing*, 14(21), 5515. <https://doi.org/10.3390/rs14215515>
- Antoniou, V., & Potsiou, C. (2020). A Deep Learning Method to Accelerate the Disaster Response Process. In *Remote Sensing*, 12 (3), 544. <https://doi.org/10.3390/rs12030544>
- 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>
- Ball, J. G. C., Petrova, K., Coomes, D. A., & Flaxman, S. (2022). Using deep convolutional neural networks to forecast spatial patterns of Amazonian deforestation. *Methods in Ecology and Evolution*, 13(11), 2622–2634. <https://doi.org/10.1111/2041-210X.13953>
- Boroujeni, S. P. H., Razi, A., Khoshdel, S., Afghah, F., Coen, J. L., O'Neill, L., Fule, P., Watts, A., Kokolakis, N.-M. T., & Vamvoudakis, K. G. (2024). A comprehensive survey of research towards AI-enabled unmanned aerial systems in pre-, active-, and post-wildfire management, *Information Fusion*, 108, 102369. <https://doi.org/10.1016/j.inffus.2024.102369>
- Chamatidis, I., Istrati, D., & Lagaros, N. D. (2024). Vision Transformer for Flood Detection Using Satellite Images from Sentinel-1 and Sentinel-2. In *Water*, 16, (12), 1670. <https://doi.org/10.3390/w16121670>
- Cilli, R., Elia, M., D'Este, M., Giannico, V., Amoroso, N., Lombardi, A., Pantaleo, E., Monaco, A., Sanesi, G., Tangaro, S., Bellotti, R., & Laforzezza, R. (2022). Explainable artificial intelligence (XAI) detects wildfire occurrence in the Mediterranean countries of Southern Europe. *Scientific Reports*, 12(1), 16349. <https://doi.org/10.1038/s41598-022-20347-9>
- Costache, R., Pal, S. C., Pande, C. B., Islam, A. R. Md. T., Alshehri, F., & Abdo, H. G. (2024). Flood mapping based on novel ensemble modeling involving the deep learning, Harris Hawk optimization algorithm and stacking based machine learning. *Applied Water Science*, 14(4), 78. <https://doi.org/10.1007/s13201-024-02131-4>
- Fayaz, J., Astroza, R., Angione, C., & Medalla, M. (2024). Data-driven analysis of crustal and subduction seismic environments using interpretation of deep learning-based generalized ground motion models. *Expert Systems*

- with Applications*, 238, 121731. <https://doi.org/10.1016/j.eswa.2023.121731>
- Fayaz, J., & Galasso, C. (2024). Interpretability and spatial efficacy of a deep-learning-based on-site early warning framework using explainable artificial intelligence and geographically weighted random forests. *Geoscience Frontiers*, 15(5), 101839. <https://doi.org/10.1016/j.gsf.2024.101839>
- Furquim, G., Filho, G. P. R., Jalali, R., Pessin, G., Pazzi, R. W., & Ueyama, J. (2018). How to Improve Fault Tolerance in Disaster Predictions: A Case Study about Flash Floods Using IoT, ML and Real Data. In *Sensors*, 18, (3), 907. <https://doi.org/10.3390/s18030907>
- Garduño, E., Ciprián-Sánchez, J., Vázquez-García, V., González-Mendoza, M., Rodríguez-Hernández, G., Palacios-Rosas, A., & Rossi-Tisson, L., & Ochoa-Ruiz, G. (2023). An FPGA Smart Camera Implementation of Segmentation Models for Drone Wildfire Imagery. *Computación y Sistemas*, 27(4), 965–977. <https://doi.org/10.48550/arXiv.2309.01318>
- Ge, Q., Li, J., Lacasse, S., Sun, H., & Liu, Z. (2024). Data-augmented landslide displacement prediction using generative adversarial network. *Journal of Rock Mechanics and Geotechnical Engineering*, 16(10), 4017–4033. <https://doi.org/10.1016/j.jrmge.2024.01.003>
- Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S. R., Tiede, D., & Aryal, J. (2019). Evaluation of Different Machine Learning Methods and Deep-Learning Convolutional Neural Networks for Landslide Detection. In *Remote Sensing*, 11, (2), 196. <https://doi.org/10.3390/rs11020196>
- Gupta, R., & Kim, H. (2024). A Geospatial Approach to Wildfire Risk Modeling Using Machine Learning and Remote Sensing Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 13570–13576. <https://doi.org/10.1109/JSTARS.2024.3434368>
- Ian, V.-K., Tang, S.-K., & Pau, G. (2023). Assessing the Risk of Extreme Storm Surges from Tropical Cyclones under Climate Change Using Bidirectional Attention-Based LSTM for Improved Prediction. In *Atmosphere*, 14, (12), 1749. <https://doi.org/10.3390/atmos14121749>
- Jung, D., Tran Tuan, V., Quoc Tran, D., Park, M., & Park, S. (2020). Conceptual Framework of an Intelligent Decision Support System for Smart City Disaster Management. In *Applied Sciences*, 10, (2), 666. <https://doi.org/10.3390/app10020666>
- Khan, S., & Khan, A. (2022). FFireNet: Deep Learning Based Forest Fire Classification and Detection in Smart Cities. In *Symmetry*, 14, (10), 2155. <https://doi.org/10.3390/sym14102155>
- Khan, T. A., Alam, M. M., Shahid, Z., & Su'ud, M. M. (2020). Prior Recognition of Flash Floods: Concrete Optimal Neural Network Configuration Analysis for Multi-Resolution Sensing. *IEEE Access*, 8, 210006–210022. <https://doi.org/10.1109/ACCESS.2020.3038812>
- Knutson, T., Camargo, S. J., Chan, J. C. L., Emanuel, K., Ho, C.-H., Kossin, J., Mohapatra, M., Satoh, M., Sugi, M., Walsh, K., & Wu, L. (2020). Tropical Cyclones and Climate Change Assessment: Part II: Projected Response to Anthropogenic Warming. *Bulletin of the American Meteorological Society*, 101(3), E303-E322. <https://doi.org/10.1175/BAMS-D-18-0194.1>
- Kumar, M. A., & Laxmi, A. J. (2021). Machine Learning Based Intentional Islanding Algorithm for DERs in Disaster Management. *IEEE Access*, 9, 85300–85309. <https://doi.org/10.1109/ACCESS.2021.3087914>
- Lee, S.-M., & Lee, S.-J. (2024). Landslide susceptibility assessment of South Korea using stacking ensemble machine learning. *Geoenvironmental Disasters*, 11(1), 7. <https://doi.org/10.1186/s40677-024-00271-y>
- Lelis, C. A. S., Roncal, J. J., Silveira, L., Aquino, R. D. G. De, Marcondes, C. A. C., Marques, J., Loubach, D. S., Verri, F. A. N., Curtis, V. V., & Souza, D. G. De. (2024). Drone-Based AI System for Wildfire Monitoring and Risk Prediction. *IEEE Access*, 12, 139865–139882. <https://doi.org/10.1109/ACCESS.2024.3462436>
- Li, H., Vulova, S., Rocha, A. D., & Kleinschmit, B. (2024). Spatio-temporal feature attribution of European summer wildfires with Explainable Artificial Intelligence (XAI). *Science of The Total Environment*, 916, 170330. <https://doi.org/10.1016/j.scitotenv.2024.170330>
- Liberati, A., Altman, D. G., Tetzlaff, J., Mulrow, C., Gøtzsche, P. C., Ioannidis, J. P. A., Clarke, M., Devereaux, P. J., Kleijnen, J., & Moher, D. (2009). The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate healthcare interventions: explanation and elaboration. *BMJ*, 339, b2700. <https://doi.org/10.1136/bmj.b2700>
- Liu, S., Liu, Y., Chu, Z., Yang, K., Wang, G., Zhang, L., & Zhang, Y. (2023). Evaluation of Tropical Cyclone Disaster Loss Using Machine Learning Algorithms with an explainable Artificial Intelligence Approach. In *Sustainability*, 15, (16). <https://doi.org/10.3390/su151612261>
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & Group, T. P. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLOS Medicine*, 6(7), e1000097.

- <https://doi.org/10.1371/journal.pmed.1000097>
- Moreno, J. M., Sánchez, J. M., & Espitia, H. E. (2020). Use of computational intelligence techniques to predict flooding in places adjacent to the Magdalena River. *Heliyon*, 6(9), e04872. <https://doi.org/10.1016/j.heliyon.2020.e04872>
- Mowll, R., Anderson, M. J., Logan, T. M., Becker, J. S., Wotherspoon, L. M., Stewart, C., Johnston, D., & Neely, D. (2024). A new mapping tool to visualise critical infrastructure levels of service following a major earthquake. *Progress in Disaster Science*, 21, 100312. <https://doi.org/10.1016/j.pdisas.2024.100312>
- Oyounalsoud, M. S., Yilmaz, A. G., Abdallah, M., & Abdeljaber, A. (2024). Drought prediction using artificial intelligence models based on climate data and soil moisture. *Scientific Reports*, 14(1), 19700. <https://doi.org/10.1038/s41598-024-70406-6>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, 71. <https://doi.org/10.1136/bmj.n71>
- Pang, Y., Li, Y., Feng, Z., Feng, Z., Zhao, Z., Chen, S., & Zhang, H. (2022). Forest Fire Occurrence Prediction in China Based on Machine Learning Methods. In *Remote Sensing*, 14, (21), 5546. <https://doi.org/10.3390/rs14215546>
- Peduzzi, P., Chatenoux, B., Dao, H., De Bono, A., Herold, C., Kossin, J., Mouton, F., & Nordbeck, O. (2012). Global trends in tropical cyclone risk. *Nature Climate Change*, 2(4), 289–294. <https://doi.org/10.1038/nclimate1410>
- Poslad, S., Middleton, S. E., Chaves, F., Tao, R., Necmioglu, O., & Bügel, U. (2015). A Semantic IoT Early Warning System for Natural Environment Crisis Management. *IEEE Transactions on Emerging Topics in Computing*, 3(2), 246–257. <https://doi.org/10.1109/TETC.2015.2432742>
- Rahmati, O., Ghorbanzadeh, O., Teimurian, T., Mohammadi, F., Tiefenbacher, J. P., Falah, F., Pirasteh, S., Ngo, P.-T. T., & Bui, D. T. (2019). Spatial Modeling of Snow Avalanche Using Machine Learning Models and Geo-Environmental Factors: Comparison of Effectiveness in Two Mountain Regions. In *Remote Sensing*, 11, (24). <https://doi.org/10.3390/rs11242995>
- Rahnemoonfar, M., Chowdhury, T., Sarkar, A., Varshney, D., Yari, M., & Murphy, R. R. (2021). FloodNet: A High Resolution Aerial Imagery Dataset for Post Flood Scene Understanding. *IEEE Access*, 9, 89644–89654. <https://doi.org/10.1109/ACCESS.2021.3090981>
- Rosi, A. (2023). Exploring the Use of Pattern Classification Approaches for the Recognition of Landslide-Triggering Rainfalls. In *Sustainability*, 15, (20). <https://doi.org/10.3390/su152015145>
- 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>
- Seeja, G., Doss, A. S. A., & Hency, V. B. (2023). A Novel Approach for Disaster Victim Detection Under Debris Environments Using Decision Tree Algorithms With Deep Learning Features. *IEEE Access*, 11, 54760–54772. <https://doi.org/10.1109/ACCESS.2023.3281461>
- Sun, H., Wang, J., & Ye, W. (2021). A Data Augmentation-Based Evaluation System for Regional Direct Economic Losses of Storm Surge Disasters. In *International Journal of Environmental Research and Public Health*, 18 (6). <https://doi.org/10.3390/ijerph18062918>
- Sun, X., Li, N., Chen, D., Chen, G., Sun, C., Shi, M., Gao, X., Wang, K., & Hezam, I. M. (2024). A Forest Fire Prediction Model Based on Cellular Automata and Machine Learning. *IEEE Access*, 12, 55389–55403. <https://doi.org/10.1109/ACCESS.2024.3389035>
- Supriya, Y., & Gadekallu, T. R. (2023). Particle Swarm-Based Federated Learning Approach for Early Detection of Forest Fires. In *Sustainability*, 15, (2). <https://doi.org/10.3390/su15020964>
- Teoh, J., Zulkoffli, Z. B., Yap, K. M., & Chua, H. S. (2024). Exploring Generative AI for YOLO-Based Object Detection to Enhance Flood Disaster Response in Malaysia. *IEEE Access*, 12, 173686–173699. <https://doi.org/10.1109/ACCESS.2024.3498893>
- Wahba, M., El-Rawy, M., Al-Arifi, N., & Mansour, M. M. (2023). A Novel Estimation of the Composite Hazard of Landslides and Flash Floods Utilizing an Artificial Intelligence Approach. In *Water* 15 (23). <https://doi.org/10.3390/w15234138>
- Wang, Z., & Brenning, A. (2023). Unsupervised active-transfer learning for automated landslide mapping. *Computers & Geosciences*, 181, 105457. <https://doi.org/10.1016/j.cageo.2023.105457>
- Xue, Z., Xu, C., & Xu, X. (2023). Application of ChatGPT in natural disaster prevention and reduction. *Natural Hazards Research*, 3(3), 556–562. <https://doi.org/10.1016/j.nhres.2023.07.005>
- 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>
- Yu, D., & He, Z. (2022). Digital twin-driven intelligence disaster prevention and mitigation for infrastructure: advances, challenges, and opportunities. *Natural Hazards*, 112(1), 1–36. <https://doi.org/10.1007/s11069-021-05190-x>
- Zambrano, A. M., Perez, I., Palau, C., & Esteve, M. (2017). Technologies of Internet of Things applied to an Earthquake Early Warning System. *Future Generation Computer Systems*, 75, 206–215. <https://doi.org/10.1016/j.future.2016.10.009>
- Zhou, C., Yin, K., Cao, Y., Ahmed, B., Li, Y., Catani, F., & Pourghasemi, H. R. (2018). Landslide susceptibility modeling applying machine learning methods: A case study from Longju in the Three Gorges Reservoir area, China. *Computers & Geosciences*, 112, 23–37. <https://doi.org/10.1016/j.cageo.2017.11.019>