

Machine Learning-Based Prediction Models to improve the Accuracy of early earthquake detection in cities: A Systematic Review

Anthony Gerard Espiritu Bustamante¹; Catherin Karla Carhuapuma Amanqui²; Evelyn Elizabeth Ayala Ñiquen³;
Cesar Augusto Yactayo Arias⁴
^{1, 2, 3, 4} Universidad Tecnológica del Perú, Perú, u23222071@utp.edu.pe, u20235282@utp.edu.pe, c26915@utp.edu.pe,
c31501@utp.edu.pe

Abstract– Earthquakes cause significant losses, which demands more efficient strategies for early detection and damage assessment. Given the limitations of traditional methods, this Systematic Literature Review (SLR) aimed to analyze Machine Learning (ML) models applied to seismology to strengthen urban seismic risk management. A rigorous search was conducted in Scopus and Web of Science, yielding 335 articles. After applying inclusion/exclusion criteria and filters, 32 final articles were selected. The results revealed that algorithms such as Convolutional Neural Networks (CNN), Support Vector Machines (SVM), Random Forest, Long Short-Term Memory networks (LSTM), and Artificial Neural Networks (ANN) show great potential in improving the accuracy of early detection of seismic events (P-waves, hypocentral parameters) and in the estimation of structural damage, thereby optimizing response efficiency. However, challenges were identified regarding data availability and quality, as well as model generalization. In conclusion, ML models are a promising tool for urban seismic management, and it is crucial to address existing barriers and explore future research directions to maximize their impact.

Keywords– Earthquake, Accuracy, Machine Learning.

Modelos de predicción basados en Machine Learning para mejorar la precisión en la detección temprana de terremotos en ciudades: Una revisión sistemática.

Anthony Gerard Espiritu Bustamante¹; Catherin Karla Carhuapuma Amanqui²; Evelyn Elizabeth Ayala Ñiquen³;

Cesar Augusto Yactayo Arias⁴

^{1, 2, 3, 4} Universidad Tecnológica del Perú, Perú, u23222071@utp.edu.pe, u20235282@utp.edu.pe, c26915@utp.edu.pe, c31501@utp.edu.pe

Resumen– Los terremotos causan pérdidas significativas, lo que exige estrategias más eficientes para su detección temprana y evaluación de daños. Ante la limitación de métodos tradicionales, esta revisión sistemática de la literatura (RSL) tuvo como objetivo analizar modelos de Machine Learning (ML) aplicados a la sismología para fortalecer la gestión del riesgo sísmico urbano. Para ello, se realizó una búsqueda rigurosa en Scopus y WOS, obteniendo 335 artículos. Tras la aplicación de filtros y criterios de inclusión/exclusión, se seleccionaron 32 artículos finales. Los resultados revelaron que algoritmos como Redes Neuronales Convolucionales (CNN), Máquinas de Vectores de Soporte (SVM), Random Forest, Redes Neuronales Recurrentes (LSTM) y Redes Neuronales Artificiales (ANN) demuestran un gran potencial en la mejora de la precisión para la detección temprana de eventos sísmicos (ondas P, parámetros hipocentrales) y en la estimación de daños estructurales, optimizando la eficiencia de respuesta. Sin embargo, se identificaron retos en la disponibilidad y calidad de datos, así como en la generalización de modelos. En conclusión, los modelos de ML son una herramienta prometedora para la gestión sísmica urbana, siendo crucial abordar las barreras existentes y explorar futuras líneas de investigación para maximizar su impacto

Palabras clave– terremoto, precisión, Machine Learning.

I. INTRODUCCIÓN

Los terremotos de gran magnitud han tenido un impacto grande en las ciudades, causando pérdidas humanas, desplazamiento de la población, colapso de infraestructura y daños económicos [1], [2],[3],[4], [5], [6], [7]. Debido a la naturaleza impredecible y destructiva de estos acontecimientos es necesario contar con estrategias que ayuden a contrarrestar su efecto y sea más efectiva la respuesta de emergencia [2], [3], [8]. El entendimiento rápido y completo de los daños ayudará a que sea más efectivo el desplazamiento del personal de rescate y a la toma de decisiones críticas [4], [6], [9].

Habitualmente, la evaluación de daños y la investigación post terremoto, se han realizado en gran medida de manera

manual, tal como las inspecciones in situ y las encuestas de campo, así como de técnicas como el Rapid Visual Screening (RVS) [2], [6],[10]. Incluso cuando estos enfoques brindan información eficaz, son lentos, costosos y trabajosos, lo que limita su capacidad para cubrir las áreas afectadas y proporcionar información adecuada para la toma de decisiones [2], [6], [8], [10], [11]. La teledetección es una herramienta que permite observar y brinda respuestas claras, debido a que se puede recopilar información sin estar físicamente en el punto [12][5], [6], [9].

Pese a los avances significativos de la tecnología, la predicción de los terremotos sigue siendo un reto [13]. Los métodos habituales, como el algoritmo STA/LTA (Short-Term Average/Long-Term Average) y el criterio de información de Akaike (AIC), presentan limitaciones, como la susceptibilidad a los ruidos o a las falsas detecciones, lo que aminora su confiabilidad [8]. Asimismo, los métodos de aprendizaje automáticos y comunes necesitan una selección manual, lo que resulta trabajoso y poco efectivo. Existe una necesidad de mejorar la fuerza y extensión de los modelos actuales, que a veces son muy característicos de la zona de estudio [6], [14]. Igualmente, las metodologías de ML, que evalúan los daños en edificios post-terremoto, aún pueden ser deficientes, especialmente cuando se trata de características categóricas en los conjuntos de datos [7]. La falta de modelos que comparen sistemáticamente diferentes enfoques, covariables y tipos de impacto en la predicción del impacto de los terremotos es una brecha notable [3]. Además, se ha demostrado una gran capacidad en la clasificación del tipo de estructura de los edificios para evaluar su fragilidad y su resistencia sísmica, de la misma manera para detectar y clasificar los daños de la infraestructura con imágenes de teledetección y datos de redes sociales [9], [3], [10], [11], [16], [17] [4], [5], [6], [13], [18], [19], [20], [21], [22].

La finalidad de este estudio de investigación es evaluar de manera completa los modelos de Machine Learning aplicados en la detección temprana de sismos y la estimación de daños, con el fin de determinar aquellos que ofrecen mayor precisión en entornos urbanos.

En tal sentido, el documento está organizado de la siguiente manera: La Sección 2, Metodología, detalla el método de la Revisión Sistemática de la Literatura (RSL), cubriendo desde las preguntas de investigación mediante el marco PICO, hasta el proceso de selección de artículos primarios, descrito mediante el diagrama PRISMA. La Sección 3, Resultados, presenta los hallazgos del análisis de los trabajos seleccionados, explorando los principios y algoritmos de aprendizaje automático (CNN, SVM, LSTM, ANN) aplicados a la detección sísmica y evaluación de daños, incluyendo modelos para sistemas de alerta temprana y evaluación de daños post-terremoto, así como las fuentes de datos y técnicas de ingeniería de características. En la Sección 4, Discusión, se analiza críticamente los modelos y tecnologías identificados, ofreciendo una visión general del estado del arte, perspectivas y limitaciones en la aplicación del machine learning para la gestión del riesgo sísmico. Finalmente, en la Sección 5, Conclusiones, se sintetizan los principales hallazgos y limitaciones de esta RSL, propone posibles líneas de investigación futura en el área.

II. METODOLOGÍA

A. Estrategia de Búsqueda

En este estudio, la revisión sistemática se realizó sin metaanálisis. Para plantear los componentes de la investigación se utilizó el método PICO (problema, intervención, resultados, contexto). Encontraremos los componentes en la tabla I:

TABLA I
COMPONENTES DE LA ESTRATEGIA PICO

Componente	Detalle
(P) roblema	Predicción de terremotos
(I)ntervención	Machine Learning
(O)utcome	Detección temprana de terremotos
(C)ontexto	Ciudades

Dentro del desarrollo de la investigación, se prosiguió con el método PICO formulando la pregunta principal: ¿Qué modelos de Machine Learning ofrecen mejor precisión en la detección temprana de sismos y la estimación de daños en entornos urbanos? Con ello clasificamos las subpreguntas que están alineadas a los componentes:

TABLA II
SUBPREGUNTAS PICO

Acrónimo	RQ
P	¿Qué desafíos relacionados con los aspectos técnicos, limitaciones en la calidad de datos, condiciones y restricciones urbanas, dificultan la predicción temprana de terremotos en entornos urbanos?
I	¿Qué modelos de Machine Learning lo hacen adecuado para la predicción temprana de terremotos?
O	¿Qué soluciones basadas en modelos de Machine Learning han mejorado la detección temprana de terremotos?
C	¿En qué ciudades se implementan modelos de predicción para la detección temprana de terremotos?

Siguiendo con la investigación, se indagaron palabras clave alineadas a cada componente para facilitar la búsqueda en las bases de datos. Para ello, aproximadamente en abril de 2025, se utilizaron las plataformas bibliográficas y de información científica Scopus y WoS (Web of Science) para encontrar los artículos según las palabras clave detalladas en la Tabla III.

TABLA III
PALABRAS CLAVES DE LOS COMPONENTES PICO

Acrónimo	Palabras claves	Keywords
P	"terremoto", "sísmico", "predicción de terremotos", "pronóstico sísmico", "predicción sísmica", "sistema de alerta sísmica*", "modelo predictivo de terremotos*", "predicción de eventos sísmicos", "detección temprana de terremotos", "sistema de predicción sísmica*", "sistema de monitoreo sísmico*", "peligro sísmico", "peligro de terremoto", "riesgo sísmico", "riesgo de terremoto", "alerta temprana de terremotos", "pronóstico de eventos sísmicos", "pronóstico de actividad sísmica", "detección de terremotos", "monitoreo sísmico"	earthquake* OR seismic* OR "earthquake prediction" OR "seismic forecasting" OR "seismic prediction" OR "seismic alert system*" OR "earthquake predictive model*" OR "seismic event prediction" OR "early earthquake detection" OR "seismic prediction system*" OR "seismic monitoring system*" OR "seismic hazard" OR "earthquake hazard" OR "seismic risk" OR "earthquake risk" OR "earthquake early warning" OR "seismic event forecasting" OR "seismic activity forecasting" OR "earthquake detection" OR "seismic monitoring"
I	"Machine Learning", "Aprendizaje automático", "Aprendizaje de máquinas", "Aprendizaje computacional", "Aprendizaje estadístico", "Aprendizaje basado en datos", "Redes neuronales", "Redes neuronales artificiales", "Máquina de vectores de soporte"	"machine learning" OR "automated learning" OR "computational learning" OR "statistical learning" OR "data-driven learning" OR "neural networks" OR "artificial neural networks" OR "support vector machine"
O	"alerta sísmica temprana" OR "alerta temprana de terremotos" OR "precisión" OR "exactitud" OR "tiempo de alerta" OR "eficacia" OR "fiabilidad"	"early seismic alert" OR "early earthquake alert" OR "accuracy" OR "precision" OR "alert time" OR "effectiveness" OR "reliability"
C	"ciudades", "localidad", "población", "ciudades periféricas", "centros urbanos", "metrópolis", "núcleo urbano"	"cities" OR "locality" OR "population" OR "peripheral cities" OR "urban centers" OR "metropolis" OR "urban core"

B. Ecuación de búsqueda

La ecuación de búsqueda fue realizada uniendo las palabras claves con caracteres lógicos, formando las siguientes sucesiones con la que se realizó la búsqueda en las dos bases de datos, indicadas en la tabla IV.

TABLA IV
ECUACIÓN DE BÚSQUEDA

Scopus	Web of Science
(TITLE-ABS-KEY (earthquake* OR seismic* OR "earthquake prediction" OR "seismic forecasting" OR "seismic prediction" OR "seismic alert system*" OR "earthquake predictive model*" OR "seismic event prediction" OR "early earthquake detection" OR "seismic prediction system*" OR "seismic monitoring system*" OR "seismic hazard" OR "earthquake hazard" OR "seismic risk" OR "earthquake risk" OR "earthquake early warning" OR "seismic event forecasting" OR "seismic activity forecasting" OR "earthquake detection" OR "seismic monitoring")) AND (TITLE-ABS-KEY("machine learning" OR "automated learning" OR "computational learning" OR "statistical learning" OR "data-driven learning" OR "neural networks" OR "artificial neural networks" OR "support vector machine")) AND (TITLE-ABS-KEY("early seismic alert" OR "early earthquake alert" OR "seismic alert system" OR "early earthquake detection system" OR "early seismic event detection" OR "seismic warning system" OR "early warning system for earthquakes" OR accuracy OR precision OR "alert time" OR "effectiveness" OR "reliability")) AND (TITLE-ABS-KEY ("cities" OR "locality" OR "population" OR "peripheral cities" OR "urban centers" OR "metropolis" OR "urban core"))	TS=(earthquake* OR seismic* OR "earthquake prediction" OR "seismic forecasting" OR "seismic prediction" OR "seismic alert system*" OR "earthquake predictive model*" OR "seismic event prediction" OR "early earthquake detection" OR "seismic prediction system*" OR "seismic monitoring system*" OR "seismic hazard" OR "earthquake hazard" OR "seismic risk" OR "earthquake risk" OR "earthquake early warning" OR "seismic event forecasting" OR "seismic activity forecasting" OR "earthquake detection" OR "seismic monitoring") AND TS=("machine learning" OR "automated learning" OR "computational learning" OR "statistical learning" OR "data-driven learning" OR "neural networks" OR "artificial neural networks" OR "support vector machine") AND TS=("early seismic alert" OR "early earthquake alert" OR "seismic alert system" OR "early earthquake detection system" OR "early seismic event detection" OR "seismic warning system" OR "early warning system for earthquakes" OR accuracy OR precision OR "alert time" OR "effectiveness" OR "reliability") AND TS= ("cities" OR "locality" OR "population" OR "peripheral cities" OR "urban centers" OR "metropolis" OR "urban core"))

C. Criterios de inclusión y exclusión

Para la investigación, se contempló los criterios tanto de inclusión y exclusión. Se consideraron los siguientes:

TABLA V
CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Criterios de Inclusión	Criterios de Exclusión
CI1: Estudios que apliquen técnicas de ML en terremotos.	CE1: Estudios sobre otros desastres naturales sin conexión con terremotos.
CI2: Investigaciones que describan modelos o enfoques de análisis, predicción, clasificación o evaluación.	CE2: Estudios que no se enfoquen en ciudades sísmicamente activas.
CI3: Estudios aplicados en entornos urbanos o que incluyan edificios/infraestructura.	CE3: Investigaciones basadas exclusivamente en métodos físicos/tradicionales, sin integración con modelos computacionales.
CI4: Estudios que presenten métricas de desempeño del modelo aplicado.	

D. Proceso de selección de estudio

Con la metodología PRISMA, fueron evaluados los artículos en las bases de datos, tanto en Scopus y WOS se obtuvo un total de 335 artículos. Finalizando con 32 artículos elegibles para la investigación.




Fig. 1 Diagrama de flujo PRISMA

III. RESULTADOS

El análisis bibliométrico de palabras clave, realizado con el software VOSviewer, reveló las principales líneas temáticas concurrentes, identificando cinco clústeres conceptuales claramente definidos: el clúster verde, que agrupa los fundamentos metodológicos de los sistemas de alerta temprana (earthquakes, early warning, deep learning y convolutional neural networks); el clúster rojo, que concentra indagaciones enfocadas en la caracterización y evaluación de sismos (earthquake magnitude, clasificación y accuracy assessment); el clúster azul, orientado hacia la infraestructura y gestión del riesgo (risk assessment, damage detection y disaster management) y el clúster amarillo, que comprende tecnologías de soporte (remote sensing, support vector machines y neural networks). Ver Fig. 2.




Fig. 2 Análisis bibliométrico de palabras claves.

En la Fig. 3 se identificó cuatro clústeres señalados en colores: verde, liderado por Estados Unidos; el rojo, con Alemania como núcleo; el amarillo, integrado por Reino Unido, Suiza y Países Bajos; y el azul, incluye a China, Pakistán, Italia y Turquía.




Fig. 3 Análisis bibliométrico por países

A. Aspectos técnicos, limitaciones en la calidad de datos, condiciones y restricciones urbanas, que dificultan la predicción temprana de terremotos en entornos urbanos

El análisis exhaustivo de los artículos revisados para la Figura 4 ha permitido sintetizar los aspectos técnicos más relevantes que afectan la predicción temprana de eventos sísmicos. Esta figura ilustra la proporción relativa de publicaciones que abordan una dificultad específica, agrupando los estudios en siete categorías temáticas. Esto facilita la identificación de las barreras técnicas más frecuentes y la distribución del enfoque investigativo. Seis de estas categorías, cada una representando el 14.8% de las menciones, fueron recurrentes: la imprevisibilidad inherente del fenómeno sísmico [9], [10], [23], [24], la alta incertidumbre en las simulaciones del movimiento del suelo debido a las limitaciones de los modelos computacionales y la escasez de datos confiables [2], [4], [8], [16], la problemática de la zona ciega en los sistemas de alerta temprana (EEWS) por la insuficiente cobertura de sensores [1], [21], [25], [26]. También se identificó la complejidad en la propagación de las ondas sísmicas debido a las variaciones del subsuelo [6], [13], [27], [28], la significativa dependencia de modelos de velocidad del terreno que

condicionan las estimaciones sísmicas [2], [4], [13], [16], y la influencia de factores geográficos y del terreno que alteran la intensidad local de los sismos [13], [21], [25], [27]. Finalmente, una categoría menos representada, con un 11.1% de las menciones, fue la baja densidad de estaciones sismológicas [6], [7], [29]. Este aspecto persiste como un obstáculo para una cobertura eficiente, especialmente en regiones de difícil acceso, subrayando así la necesidad de fortalecer estas áreas clave para mejorar la capacidad de predicción sísmica.




Fig. 4 Aspectos técnicos que dificultan la predicción temprana

La información extraída de 32 artículos reveló la distribución de las limitaciones en la calidad de los datos, destacando que las más críticas, con un 11.6% de incidencia, son la alta presencia de ruido en las señales sísmicas [8], [17], [27], [30], [31] y el uso de datos desactualizados [1], [5], [26], [27], [31]. Las limitaciones clasificadas como moderadas, con un 9.3% de aparición, abarcan problemas como imágenes borrosas, ocluidas o inclinadas [9], [10], [23], [24], el desequilibrio en las clases de daño [6], [9], [18], [23] y la carencia de datos etiquetados necesarios para el entrenamiento de modelos [4], [10], [17], [32]. Finalmente, se identificó una limitación menos prevalente, con una frecuencia del 2.3%, relacionada con el ruido y la variabilidad presentes en los datos obtenidos de redes sociales, la cual fue mencionada en un solo artículo [4].




Fig. 5 Limitaciones en la calidad de datos que afecta la detección sísmica

De nueve publicaciones seleccionadas, se lograron identificar cinco factores importantes relacionados con las condiciones urbanas que incurren en la exposición al riesgo sísmico; la Fig. 6 ilustra los estudios que abordan cada una de estas problemáticas, lo que ayuda a la identificación de temas recurrentes. Entre las condiciones, las que más destacan son las

fallas estructurales y de construcción [9], [20], así como la planificación urbana y uso del suelo [6], [13]; también se reporta la carencia de información sobre infraestructura urbana [16], [26], lo que limita las capacidades de respuesta y evaluación del riesgo. Otro aspecto abordado es la vulnerabilidad económica [11], [28] , la cual aumenta los efectos del terremoto sobre las ciudades más expuestas. Por último, algunos trabajos advierten sobre la tecnología y evaluaciones previas [3] para el análisis preventivo del entorno urbano frente a situaciones sísmicas.




Fig. 6 Condiciones Urbanas antes de un sismo

En la tabla VI, entre los 16 artículos analizados, los códigos de construcción anticuados [4], [25], [32],[5], [7], [13], [21], [28] y planificación deficiente [4] [20],[24], [14], [29], [7], [21], [25] son los desafíos más frecuentes en el cual refleja una gran previsión por la falta de actualización normativa. Le siguen la planificación urbana deficiente y códigos anticuados, que destacan por su impacto en la vulnerabilidad sísmica. Además, se destacaron los desafíos de crecimiento urbano y limitaciones de datos como obstáculos recurrentes. Otros desafíos, como el desarrollo desequilibrado, se identificó con menor frecuencia [12], [27], [31].

TABLA VI
 DESAFÍOS EN LAS RESTRICCIONES URBANAS

Desafío \ Artículo	[4]	[24]	[20]	[32]	[31]	[27]	[25]	[5]	[21]	[26]	[7]	[14]	[12]	[28]	[13]
Crecimiento Urbano		•	•				•			•		•			
Códigos Anticuados	•			•			•	•	•		•			•	•
Limitaciones Datos	•							•	•		•				•
Planificación Def.	•		•	•	•				•		•	•			
Desarrollo Desequilibrado					•	•							•		

B. Modelos de Machine Learning adecuados para la predicción temprana de terremotos

La Fig. 7 ilustra la frecuencia de aparición de estos modelos y algoritmos en los artículos revisados; entre los enfoques más comunes, el modelo Support Vector Machine (SVM) destacó en ocho publicaciones [3], [4], [16], [20], [22], [23], [27], [31], siendo utilizado generalmente en labores de clasificación y predicción. Otros algoritmos utilizados, aunque con menor frecuencia, incluyen Naive Bayes [3], [4], XGBoost [7], [15], K-Nearest Neighbors (KNN) [7], [29]. Asimismo, se detectaron aplicaciones de modelos como LightGBM [7], [12], LSTM [12] y PCA [26]. Estos resultados evidencian la integración de estos modelos de aprendizaje automático, particularmente el modelo SVM, demostrando su adaptabilidad en diferentes tipos de datos y escenarios urbanos.




Fig. 7 Modelos y algoritmos de machine learning más recurrentes en los estudios revisados.

La integración de modelos de machine learning (ML) y deep learning (DL) en los sistemas de alerta temprana ante terremotos representa una línea de investigación con notable crecimiento; en este contexto, la Tabla VIII presenta una clasificación de 23 artículos en función de su nivel de aplicabilidad en sistemas de alerta temprana. Los estudios con alta aplicabilidad emplean modelos como CNN, SVM y ANN, orientados principalmente a la detección en tiempo real de eventos sísmicos [4], [7], [8], [14], [18], [21], [26], [27], [31]. En el nivel de aplicabilidad media, se agrupan investigaciones centradas en el análisis estructural, la estimación de riesgo o la clasificación geoespacial de zonas vulnerables [3], [5], [6], [12], [13], [15], [16], [19], [20], [22], [28], [32]. Finalmente, los artículos con baja aplicabilidad se enfocan en simulaciones o análisis posteriores al evento sísmico, por lo que no contribuyen directamente a la generación de alertas inmediatas [24], [25].

TABLA VII
APLICABILIDAD DE MODELOS DE ML EN SISTEMAS DE ALERTA TEMPRANA

Artículo	Aplicabilidad	Justificación resumida
Remote Sens [16]	Media	Clasificación resiliencia, más planeación.
Sustainability [7]	Alta	Entrenamiento rápido post-desastre.
International Journal of Digital Earth [28]	Alta	SVM para señales sísmicas, útil en monitoreo.
Applied Sciences (Appl. Sci.) [8]	Alta	CNN para detección de ondas P, útil en alerta.
Earth Sciences Research Journal [27]	Alta	SVM implementable en estaciones sísmicas.
Bulletin of Earthquake Engineering [6]	Media	SAR post-sismo, útil en análisis, no en alerta.
Computer-Aided Civil and Infrastructure Engineering [18]	Alta	CNN para daños post-sismo, respuesta rápida.
Engineering Science and Technology, an International Journal. [21]	Alta	CNN visuales para daños, útil en respuesta.
Scientific Reports [14]	Alta	ANN con precursores sísmicos en tiempo real.
International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. [24]	Baja	Cambio post-evento en imágenes, no alerta.
Applied Sciences [4]	Alta	Clasificación en redes sociales, alerta ciudadana.
Procedia Computer Science [12]	Media	Mapeo de subsidencia, no para alerta.
International Archives of the Photogrammetry Rem. [32]	Media	Precisión en vulnerabilidad, análisis de riesgo.
Sensors [22]	Media	Evaluación estructural y mapeo, no alerta.
Journal of Sensors. [5]	Media	Clasificación zonas de riesgo, no detección.
Acta Seismologica Sinica [26]	Alta	Simulación sísmica desde eventos menores.
Sustainability [13]	Media	Clasificación daños/riesgo, no detección.
IOP Conference Series: Earth and Environmental Science. [25]	Baja	Modelos estructurales, simulación, no alerta.
International Journal of Disaster Risk Science [3]	Media	Predicción rápida, pero no en tiempo real.
ISPRS J. Photogrammetry and Remote Sensing [20]	Media	Clasificación estructural, no detección directa.
Computer-Aided Civil and Infrastructure Engineering [15]	Media	Evaluación condicional, más análisis que alerta.
International Journal of Digital Earth [28]	Media	Evaluación estructural, no para detección.
International Journal of Disaster Risk Reduction [19]	Media	Alta precisión en vulnerabilidad, no alerta.

C. Soluciones o tecnologías basadas en modelos de Machine Learning

Entre los métodos aplicados se encuentran modelos tradicionales como las máquinas de vectores de soporte (SVM) [27] y la regresión logística [28]; también se destacan redes neuronales como las convolucionales CNN [21] y artificiales [13], [14]. A esto se suman enfoques más sofisticados como las redes LSTM [12], especialmente útiles para procesar series temporales. Asimismo, varios estudios optan por enfoques híbridos, combinando técnicas como Machine Learning con SAR [6], o integrando métodos como PCA, PSO y ML [26], lo que refleja una tendencia creciente hacia la fusión de herramientas para mejorar el rendimiento predictivo. La Figura 8 ilustra esta diversidad, destacando la riqueza y flexibilidad metodológica dentro del campo y mostrando cómo distintas tecnologías pueden adaptarse y complementarse para abordar con eficacia los desafíos de la detección sísmica temprana.




Fig. 8 Diversidad de tecnologías ML aplicadas.

D. Implementación de Modelos de Machine Learning para la detección temprana de terremotos en ciudades

En las ciudades como Almaty [8], Sanandaj [19], [32] y Bogotá [27], [31], factores como la heterogeneidad geológica, la presencia de edificaciones antiguas y la altitud influyen directamente en el desempeño de los modelos implementados. También se identifican aplicaciones en playas con riesgo de tsunamis, como Padang [20] y Metro Manila [25], así como en áreas rurales y montañosas como Shuanghe [16], donde las características del suelo, los materiales de construcción y las pendientes pronunciadas suponen desafíos técnicos adicionales para el diseño y calibración de los modelos. Napa, Haití y Japón [4], se han propuesto soluciones que integran algoritmos de ML con datos provenientes de redes sociales. Ver Tabla VIII.

TABLA VIII
CONTEXTO GEOGRÁFICO DE APLICACIÓN DEL MACHINE
LEARNING EN RIESGO SÍSMICO

Ciudad / Región	Tipo de Zona	Condiciones Locales Principales
Almaty, Kazajistán	Urbana – Montañosa	Geología diversa, terreno complejo, estaciones sísmicas a gran altitud [8]
Shuanghe, Sichuan, China	Rural – Montañosa	Fallas secundarias, alta pendiente, uso de ladrillo-hormigón [16]
Uki City, Kumamoto, Japón	Urbana – Alta Sismicidad	Alta concentración de casas de madera [18]
Sanandaj, Irán	Urbana – Montañosa	Edificaciones antiguas sin normas sísmicas; expansión urbana riesgosa [19]
Napa, Haití, Japón	Urbana densa – Sísmica	Uso de redes sociales para estimar daños; variabilidad cultural y tecnológica[4]
Padang, Indonesia	Urbana – Costera	Exposición a tsunamis; expansión urbana en zonas de riesgo[20]
Sanandaj, Irán	Urbana – Montañosa	Factores físicos y sociales integrados; vulnerabilidades estructurales y sociales [20]
Bogotá, Colombia	Urbana – Andina	Entorno urbano denso; sismicidad moderada; estación sísmica cercana[31]
Bogotá, Colombia	Urbana – Cordillera	Condiciones locales para prueba de modelo de predicción de azimuth sísmico[27]
Metro Manila, Filipinas	Urbana – Costera	Foco en estructuras de baja altura; expansión urbana informal [5], [25]
Fujairah, EAU	Costera – Montañosa	Geología, tipo de suelo, cercanía a fallas, pendiente del terreno [5]

La Tabla IX resume la tecnología o método de detección utilizado en cada artículo, la situación real en que se aplicaron y sus aspectos clave. Las Redes Neuronales aparecen como el enfoque más recurrente, presente en el 64.7% en las investigaciones[4], [13], [14], [18], [19], [21], [24], [26], [27], [31], [32]. La relación entre el tipo de técnica utilizada y su aplicación concreta se manifiesta con claridad en múltiples casos, destacando la adaptabilidad de las redes neuronales en distintas etapas del ciclo de gestión del riesgo sísmico, especialmente en contextos urbanos, simulaciones sísmicas y sistemas de alerta. Por otro lado, aunque los aspectos como “Alerta Temprana” y “Precisión”[12], [26], [27] no son tan frecuentes en los artículos (17.6%), tienen una importancia estratégica notable, ya que tienen relación directa con la capacidad de anticipar eventos sísmicos y minimizar sus efectos, lo que resulta fundamental para la protección de vidas humanas.

TABLA IX
IMPLEMENTACIONES Y RESULTADOS EN CASOS REALES

Artículo	Tecnología / Método	Aplicación Real	Aspectos
ISPRS J. Photogrammetry and Remote Sensing [20]	Teledetección multispectral + OC-SVM + SMOTE	Clasificación automática tipo estructural	

Journal of Sensors.[5]	GIS + AHP + Landsat 8	Evaluación peligro y vulnerabilidad sísmic	GIS
Engineering Science and Technology, an-International Journal [21]	CNN para clasificación imágenes	Evaluación rápida daños post-sismo	Redes Neuronales, Daños post-sismo
Bulletin of Earthquake Engineering.[6]	SAR VHR + clasificación	Clasificación daño a nivel edificio	Daños post-sismo
IOP Conference Series: Earth and Environmental Science.[25]	Modelado automatizado 3D FEM	Generación masiva de modelos estructurales	
Procedia Computer Science [12]	Alerta temprana rápida	Alerta segundos después onda P	Alerta Temprana
Sustainability [13]	ANN para vulnerabilidad social	Evaluación vulnerabilidad social urbana	Redes Neuronales, GIS, Precisión ≥90%
Earth Sciences Research Journal [27]	SVM para clasificación	Estimación rápida azimuth sísmico	Redes Neuronales, Alerta Temprana
Ingeniería e Investigación[31]	SVM para regresión	Estimación rápida de profundidad sísmica	Redes Neuronales
Acta Seismologica Sinica [26]	ML para simulación sísmica	Simulación movimiento sísmico y alerta	Redes Neuronales, Alerta Temprana
Computer-Aided Civil and Infrastructure Engineering [18]	CNN (ResNet-50)	Clasificación daños en muros, techos, cimientos	Redes Neuronales
Applied Sciences [4]	Redes sociales + SVM, NB, DL	Detección temprana daños post-sismo	Redes Neuronales, Daños post-sismo, Alerta Temprana
International Journal of Digital Earth [28]	SBAS-InSAR + GPS + LR	Monitoreo subsidencia y deformación	
Scientific Reports [14]	ANN-GA	Predicción de PGA	Redes Neuronales, Precisión ≥90%
International Archives of the Photogrammetry Rem [32]	GIS + AHP + RBFNN	Zonificación vulnerabilidad física y social	Redes Neuronales, GIS
International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives [24]	Teledetección + SVM y redes neuronales	Mapas cambio pre/post daño	Redes Neuronales, Daños post-sismo
International Journal of Disaster Risk Reduction [19]	ANN + FAHP + GIS	Mapas vulnerabilidad sísmica	Redes Neuronales, GIS, Precisión ≥90%

IV. DISCUSIÓN

La imprevisibilidad inherente de la predicción temprana de sismos representa una barrera que ha frustrado los enfoques predictivos tradicionales [1]. Uno de los principales aspectos técnicos que dificultan la predicción temprana es la alta incertidumbre asociada a las simulaciones del movimiento del suelo, a diferencia de los modelos puramente físicos, que a menudo luchan con la complejidad no lineal de los movimientos sísmicos, los estudios revisados indican que el ML, a través de técnicas como Análisis de Componentes Principales (PCA) y Optimización por Enjambre de Partículas (PSO), mejora notablemente la precisión de estas simulaciones, reduciendo significativamente los errores al contrastarlas con registros sísmicos reales [26]. En contraste con la costosa y logísticamente compleja expansión de las redes sismológicas físicas, se destaca cómo las soluciones de estación única basadas en ML ofrecen una alternativa prometedora para estimar parámetros sísmicos clave [27]. Esta aproximación es relevante en áreas remotas o de difícil acceso. La complejidad en la propagación de ondas sísmicas, influida por las heterogeneidades geográficas y del subsuelo es un aspecto técnico que ha dificultado históricamente la evaluación precisa de daños. Mientras que los modelos empíricos a menudo simplifican estas complejidades, la integración de esta información detallada en modelos de vulnerabilidad basados en ML[2], [16], [28] representa un salto cualitativo. De manera similar, la dependencia de modelos de velocidad del terreno, que afectan la exactitud de medidas físicas como Aceleración Pico del Suelo (PGA) y Velocidad Pico del Suelo (PGV), es otro factor limitante que encuentra en la inclusión de ML una vía para mejorar la precisión de estas estimaciones[2], [16], una capacidad que los métodos convencionales no siempre logran con la misma robustez.

Las limitaciones en la calidad de los datos se presentan como uno de los obstáculos más críticos para la predicción temprana de sismos. La alta presencia de ruido en las señales sísmicas [8] y en el uso de datos desactualizados [1], [27], [31] no son deficiencias operacionales; son barreras fundamentales que merman la precisión y la confiabilidad de cualquier modelo predictivo. En contraste con estos métodos convencionales, que a menudo requieren filtrados extensivos y pueden comprometer la integridad de la señal, la eficacia superior de las técnicas de aprendizaje automático (ML), particularmente las redes neuronales convolucionales (CNN), frente a relaciones señal-ruido bajas [8], [17], redefine lo que es posible en entornos ruidosos. Resulta notorio que estudios previos se vieron obligados a recurrir a información desactualizada de principios de los años 2000 [1] o 2008 [27], [31] debido a problemas de accesibilidad. Sin embargo, en contraste con esta limitación histórica, investigaciones más recientes han demostrado que la disponibilidad de registros sísmicos actuales y de alta calidad [26], [30] es fundamental para lograr resultados precisos y confiables.

Las ciudades contemporáneas se enfrentan a desafíos sísmicos críticos que, en gran medida, provienen de la arraigada problemática de códigos de construcción anticuados y una planificación urbana deficiente [5] y no son meras deficiencias operacionales; comprometiendo la seguridad y la resiliencia urbana de maneras profundas y sistémicas. Lo que exige una reevaluación urgente de las metodologías preventivas. No obstante, en claro contraste con estas barreras estructurales, se debe evaluar rápidamente el daño y la vulnerabilidad sísmica potenciado por la integración de tecnologías como el aprendizaje automático (ML)[5], [7] y la teledetección [20], [28], no solo ha agilizado el proceso, sino que ha elevado la precisión y la exhaustividad del análisis, superando las limitaciones intrínsecas de los métodos tradicionales. Además, la modelización de estructuras en 3D [25] y la estimación precisa de parámetros sísmicos como la profundidad [31] y el azimut[27] no son solo mejoras técnicas; representan una redefinición fundamental de las estrategias de resiliencia y planificación urbana [13], [14].

A pesar de estos innegables progresos, es crucial reconocer que persisten limitaciones significativas que mitigan el impacto pleno del ML en este dominio, como la calidad y el equilibrio de los datos [7], [13], [14], [21]. Además, la aplicabilidad regional limitada de los modelos [7] plantea un desafío considerable; a diferencia de los principios físicos universales, los modelos basados en datos pueden no generalizar bien a áreas con características geológicas o constructivas diferentes, lo que limita su utilidad global. La insuficiente validación en el lugar [20], [25] agrava esta situación, sugiriendo una brecha crítica entre el rendimiento teórico del modelo y su fiabilidad práctica en escenarios reales.

Cuando se examina el contexto en riesgos sísmicos, se observa una orientación estratégica hacia las grandes ciudades con alta actividad sísmica, como Almaty [8], Sanandaj [19] y Bogotá [27], [31]. Esta preferencia se justifica por la significativa vulnerabilidad urbana y la mayor disponibilidad de datos y se refuerza con la creación de modelos a escala de ciudad en lugares como Metro Manila [25]. Sin embargo, esta concentración urbana introduce un contraste crucial: la necesidad imperativa de adaptar el ML a las particularidades locales [8], [19] en otros contextos geográficos. En regiones montañosas como Shuanghe, los desafíos surgen de características específicas del suelo y materiales de construcción, sumados a un "desequilibrio de datos" [16], lo cual difiere notablemente de la riqueza de información en entornos urbanos. Otro punto de contraste es la limitada profundización en la integración explícita de modelos ML para el riesgo de tsunami en zonas costeras, a pesar de la mención de sistemas de alerta temprana [27], lo que sugiere una brecha de investigación en la creación de sistemas de alerta multihaz.

Se identificó que las Redes Neuronales (NN) constituyen el enfoque metodológico predominante (64.7%) en los estudios analizados, lo que confirma una tendencia sólida hacia el uso de técnicas avanzadas de aprendizaje automático en el ámbito sísmico [18]. Si bien estos enfoques han demostrado alto

potencial técnico, su implementación en contextos reales aún enfrenta importantes desafíos. Muchos de los trabajos revisados se enfocan en la optimización algorítmica y la precisión de los modelos, pero rara vez explicitan cómo estos desarrollos podrían integrarse en sistemas operativos de alerta o gestión del riesgo sísmico. Este desfase se refleja claramente en la escasa mención de la “Alerta Temprana” como eje temático central, presente en apenas el 17.6% de los artículos. Dada su relevancia crítica para salvar vidas en escenarios de desastre, esta baja representación plantea dudas sobre el grado de preparación de los modelos actuales para su adopción en la práctica. Los estudios podrían beneficiarse de una mayor atención a factores como la latencia de procesamiento, la conectividad de sensores, la interpretación de resultados por parte de personal no técnico, y la interoperabilidad con infraestructuras existentes. Por otro lado, si bien la “Precisión” no fue destacada en la mayoría de los estudios, varios trabajos reportan su uso como métrica fundamental de validación [18], [21]. Sin embargo, las métricas cuantitativas deben complementarse con evaluaciones en entornos reales para garantizar que los modelos no solo sean precisos en laboratorio, sino también funcionales en condiciones operativas.

Irán y China destacan por un volumen significativo de publicaciones en gestión del riesgo sísmico, lo que sugiere un compromiso sostenido con el desarrollo tecnológico en el área [1], [9]. Sin embargo, la comparación con Japón y Estados Unidos, que exhiben una producción científica más profunda y metodológicamente robusta [1], [16], cuestiona la idea de que el liderazgo en innovación pueda evaluarse únicamente por cantidad. Esto implica que la calidad y madurez del ecosistema de investigación son factores cruciales para el avance del campo. Por otro lado, la participación destacada de Haití, impulsada por el terremoto de Nippes [6], revela cómo las crisis pueden generar desarrollos puntuales, pero posiblemente no sostenibles en el tiempo, evidenciando una respuesta reactiva más que una estrategia planificada. De igual forma, Turquía y Colombia, a pesar de su clasificación inicial como actores secundarios, muestran una actividad investigativa más sólida y relevante [9], [27], lo que pone de manifiesto la importancia de complementar el análisis cuantitativo con una evaluación cualitativa del contexto. La contribución de países como Italia, Nepal y Taiwán [6], [30], [31] destaca la naturaleza global y colaborativa de la innovación en gestión del riesgo sísmico, subrayando que la relevancia y aplicabilidad local de los desarrollos tecnológicos son tan determinantes como el volumen de producción científica.

V. CONCLUSIÓN

Las técnicas más empleadas fueron las Máquinas de Vectores de Soporte (SVM), Redes Neuronales Convolucionales (CNN) y Redes Neuronales Artificiales (ANN), con desempeños destacados en tareas de clasificación y predicción. En particular, la arquitectura LSTM alcanzó una precisión del 98.2 % en la clasificación de ondas P en un

segundo, y los modelos ANN-GA obtuvieron resultados precisos en la predicción de la Aceleración Máxima del Terreno (PGA). Las SVM se destacaron por su efectividad frente a datos ruidosos y de alta dimensionalidad, alcanzando precisiones de hasta el 97.4 %. Además, los modelos híbridos que integran aprendizaje automático con principios físicos mostraron un creciente interés, mejorando tanto la precisión como la eficiencia computacional. Algunos estudios reportaron coeficientes de determinación (R^2) cercanos al 99.7 %, especialmente en regiones sísmicamente activas como Irán, China y Colombia. Entre los principales desafíos identificados se encuentran la calidad desigual de los datos sísmicos, la baja densidad de estaciones, el alto nivel de ruido, la escasa validación en condiciones reales y la dificultad de generalizar los modelos a distintos contextos geográficos. También se evidenció una limitada interpretabilidad en ciertos modelos de ML, lo que complica su adopción por parte de técnicos y tomadores de decisiones. Se recomienda, para investigaciones futuras, aumentar la recolección y el etiquetado de datos sísmicos actualizados, así como evaluar la aplicabilidad de los modelos de aprendizaje automático en contextos geográficos diversos. Asimismo, es fundamental priorizar el desarrollo de enfoques explicables y escalables que se ajusten a las necesidades de la infraestructura urbana. También se sugiere integrar variables adicionales relacionadas con riesgos, como la presencia de tsunamis y la densidad estructural, y explorar el potencial de técnicas híbridas que combinen métodos computacionales con principios físicos, a fin de superar las limitaciones actuales en cuanto a precisión, latencia y capacidad de generalización.

REFERENCIAS

- [1] H. Sheikhan, M. R. Delavar, and A. Stein, “A GIS-based multi-criteria seismic vulnerability assessment using the integration of granular computing rule extraction and artificial neural networks,” *Transactions in GIS*, vol. 21, no. 6, pp. 1237–1259, Dec. 2017, doi: 10.1111/tgis.12274.
- [2] H. Zhou, A. Che, X. Shuai, and Y. Zhang, “A spatial evaluation method for earthquake disaster using optimized BP neural network model,” *Geomatics, Natural Hazards and Risk*, vol. 14, no. 1, pp. 1–26, Dec. 2023, doi: 10.1080/19475705.2022.2160664.
- [3] H. Patten, M. Anderson Loake, and D. Steinsaltz, “Data-Driven Earthquake Multi-impact Modeling: A Comparison of Models,” *International Journal of Disaster Risk Science*, vol. 15, no. 3, pp. 421–433, Jun. 2024, doi: 10.1007/s13753-024-00567-5.
- [4] S. Ahadzadeh and M. R. Malek, “Earthquake Damage Assessment in Three Spatial Scale Using Naive Bayes, SVM, and Deep Learning Algorithms,” *Applied Sciences*, vol. 11, no. 20, p. 9737, Oct. 2021, doi: 10.3390/app11209737.
- [5] D. Al-Dogom et al., “Geospatial Multicriteria Analysis for Earthquake Risk Assessment: Case Study of Fujairah City in the UAE,” *J Sens*, vol. 2021, no. 1, Jan. 2021, doi: 10.1155/2021/6638316.
- [6] V. Macchiarulo, G. Giardina, P. Milillo, Y. D. Aktas, and M. R. Z. Whitworth, “Integrating post-event very high resolution SAR imagery and machine learning for building-level earthquake damage assessment,” *Bulletin of Earthquake Engineering*, Mar. 2024, doi: 10.1007/s10518-024-01877-1.
- [7] Y. Li, C. Jia, H. Chen, H. Su, J. Chen, and D. Wang, “Machine Learning Assessment of Damage Grade for Post-Earthquake Buildings: A Three-Stage Approach Directly Handling Categorical Features,” *Sustainability*, vol. 15, no. 18, p. 13847, Sep. 2023, doi: 10.3390/su151813847.
- [8] D. Zhaxebay et al., “Deep Learning for Early Earthquake Detection: Application of Convolutional Neural Networks for P-Wave Detection,”

- Applied Sciences, vol. 15, no. 7, p. 3864, Apr. 2025, doi: 10.3390/app15073864.
- [9] H. Xia et al., "A Deep Learning Application for Building Damage Assessment Using Ultra-High-Resolution Remote Sensing Imagery in Turkey Earthquake," *International Journal of Disaster Risk Science*, vol. 14, no. 6, pp. 947–962, Dec. 2023, doi: 10.1007/s13753-023-00526-6.
 - [10] F. Ghione, S. Mæland, A. Meslem, and V. Oye, "Building Stock Classification Using Machine Learning: A Case Study for Oslo, Norway," *Front Earth Sci (Lausanne)*, vol. 10, Jun. 2022, doi: 10.3389/feart.2022.886145.
 - [11] E. A. Moscoso Alcantara and T. Saito, "Convolutional Neural Network-Based Rapid Post-Earthquake Structural Damage Detection: Case Study," *Sensors*, vol. 22, no. 17, p. 6426, Aug. 2022, doi: 10.3390/s22176426.
 - [12] H. S. Kuyuk and O. Susumu, "Real-Time Classification of Earthquake using Deep Learning," *Procedia Comput Sci*, vol. 140, pp. 298–305, 2018, doi: 10.1016/j.procs.2018.10.316.
 - [13] M. Alizadeh et al., "Social Vulnerability Assessment Using Artificial Neural Network (ANN) Model for Earthquake Hazard in Tabriz City, Iran," *Sustainability*, vol. 10, no. 10, p. 3376, Sep. 2018, doi: 10.3390/su10103376.
 - [14] F. Khalid and M. Razbin, "Modeling peak ground acceleration for earthquake hazard safety evaluation," *Sci Rep*, vol. 14, no. 1, p. 31032, Dec. 2024, doi: 10.1038/s41598-024-82171-7.
 - [15] M. Harati and J. W. van de Lindt, "Data-driven machine learning for multi-hazard fragility surfaces in seismic resilience analysis," *Computer-Aided Civil and Infrastructure Engineering*, vol. 40, no. 6, pp. 698–720, Feb. 2025, doi: 10.1111/mice.13356.
 - [16] H. Wen, X. Zhou, C. Zhang, M. Liao, and J. Xiao, "Different-Classification-Scheme-Based Machine Learning Model of Building Seismic Resilience Assessment in a Mountainous Region," *Remote Sens (Basel)*, vol. 15, no. 9, p. 2226, Apr. 2023, doi: 10.3390/rs15092226.
 - [17] R. Tibi, L. Linville, C. Young, and R. Brogan, "Classification of Local Seismic Events in the Utah Region: A Comparison of Amplitude Ratio Methods with a Spectrogram-Based Machine Learning Approach," *Bulletin of the Seismological Society of America*, vol. 109, no. 6, pp. 2532–2544, Dec. 2019, doi: 10.1785/0120190150.
 - [18] K. Wu, M. Matsuoka, and H. Oshio, "Earthquake damage detection and level classification method for wooden houses based on convolutional neural networks and onsite photos," *Computer-Aided Civil and Infrastructure Engineering*, vol. 40, no. 5, pp. 674–694, Feb. 2025, doi: 10.1111/mice.13224.
 - [19] P. Yariyan, H. Zabihi, I. D. Wolf, M. Karami, and S. Amirian, "Earthquake risk assessment using an integrated Fuzzy Analytic Hierarchy Process with Artificial Neural Networks based on GIS: A case study of Sanandaj in Iran," *International Journal of Disaster Risk Reduction*, vol. 50, p. 101705, Nov. 2020, doi: 10.1016/j.ijdrr.2020.101705.
 - [20] C. Geiß et al., "Estimation of seismic building structural types using multi-sensor remote sensing and machine learning techniques," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 104, pp. 175–188, Jun. 2015, doi: 10.1016/j.isprsjprs.2014.07.016.
 - [21] G. Özerol Özman, S. Arslan Selçuk, and A. Arslan, "Image classification on Post-Earthquake damage assessment: A case of the 2023 Kahramanmaraş earthquake," *Engineering Science and Technology, an International Journal*, vol. 56, p. 101780, Aug. 2024, doi: 10.1016/j.jestech.2024.101780.
 - [22] C. Zhang, H. Wen, M. Liao, Y. Lin, Y. Wu, and H. Zhang, "Study on Machine Learning Models for Building Resilience Evaluation in Mountainous Area: A Case Study of Banan District, Chongqing, China," *Sensors*, vol. 22, no. 3, p. 1163, Feb. 2022, doi: 10.3390/s22031163.
 - [23] S. T. Seydi and H. Rastiveis, "A DEEP LEARNING FRAMEWORK FOR ROADS NETWORK DAMAGE ASSESSMENT USING POST-EARTHQUAKE LIDAR DATA," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-4/W18, pp. 955–961, Oct. 2019, doi: 10.5194/isprs-archives-XLII-4-W18-955-2019.
 - [24] H. Aali, A. Sharifi, and A. Malian, "EARTHQUAKE DAMAGE DETECTION USING SATELLITE IMAGES (CASE STUDY: SARPOL-ZAHAB EARTHQUAKE)," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-4/W18, pp. 1–5, Oct. 2019, doi: 10.5194/isprs-archives-XLII-4-W18-1-2019.
 - [25] J. A. B. Ramos, P. E. B. Quinay, and K. D. Q. Colegio, "Generating City-Scale 3D Finite Element Models from GIS Features and Heuristic-based Framing Models using Feed-Forward Artificial Neural Networks," *IOP Conf Ser Earth Environ Sci*, vol. 1091, no. 1, p. 012020, Nov. 2022, doi: 10.1088/1755-1315/1091/1/012020.
 - [26] K. Chen and H. Pan, "Machine Learning-Based Regional Seismic Motion Simulation: A Case Study of the Ms6.8 Earthquake in Luding in 2022," *Acta Seismologica Sinica*, vol. 46, no. 6, 2024, doi: 10.11939/jass.20230084.
 - [27] L. H. Ochoa Gutierrez, C. A. Vargas Jiménez, and L. F. Niño Vásquez, "Fast estimation of earthquake arrival azimuth using a single seismological station and machine learning techniques," *Earth Sciences Research Journal*, vol. 23, no. 2, pp. 103–109, Apr. 2019, doi: 10.15446/esrj.v23n2.70581.
 - [28] S. Hussain et al., "SBAS-InSAR Analysis of tectonic derived ground deformation and subsidence susceptibility mapping via machine learning in Quetta City, Pakistan," *Int J Digit Earth*, vol. 18, no. 1, Dec. 2025, doi: 10.1080/17538947.2024.2441926.
 - [29] F. Di Michele et al., "Comparison of machine learning tools for damage classification: the case of L'Aquila 2009 earthquake," *Natural Hazards*, vol. 116, no. 3, pp. 3521–3546, Apr. 2023, doi: 10.1007/s11069-023-05822-4.
 - [30] T. Furumura and Y. Oishi, "An Early Forecast of Long-Period Ground Motions of Large Earthquakes Based on Deep Learning," *Geophys Res Lett*, vol. 50, no. 6, Mar. 2023, doi: 10.1029/2022GL101774.
 - [31] L. H. Ochoa Gutierrez, L. F. Niño Vasquez, and C. A. Vargas Jimenez, "Fast Determination of Earthquake Depth Using Seismic Records of a Single Station, Implementing Machine Learning Techniques," *Ingeniería e Investigación*, vol. 38, no. 2, pp. 91–103, May 2018, doi: 10.15446/ing.investig.v38n2.68407.
 - [32] P. Yariyan, M. R. Karami, and R. Ali Abbaspour, "EXPLOITATION OF MCDA TO LEARN THE RADIAL BASE NEURAL NETWORK (RBFNN) AIM PHYSICAL AND SOCIAL VULNERABILITY ANALYSIS VERSUS THE EARTHQUAKE (CASE STUDY: SANANDAJ CITY, IRAN)," doi: 10.5194/isprs-archives-XLII-4-W18-1071-2019