

DOI: 10.24850/j-tyca-18-02-04

Artículos

Monitoreo en tiempo real y aprendizaje automático para evaluar y predecir la estabilidad de presas de tierra

Real-time monitoring and machine learning for evaluating and predicting the stability of earth dams

Gabriel Montúfar¹, ORCID: <https://orcid.org/0000-0003-3392-3728>

¹Universidad de Panamá, Ciudad de Panamá, Panamá,
gabriel.montufar@up.ac.pa

Autor para correspondencia: Gabriel Montúfar,
gabriel.montufar@up.ac.pa

Resumen

Las presas de tierra y enrocamiento representan casi el 80 % de las grandes presas de todo el mundo y son infraestructuras críticas para el suministro de agua, la producción hidroeléctrica y la gestión de avenidas. La seguridad de estas obras está amenazada por la filtración interna, las presiones intersticiales excesivas, las deformaciones progresivas y la erosión. Los métodos tradicionales de seguimiento, basados en lecturas manuales periódicas de piezómetros, extensómetros y asentómetros, presentan limitaciones de frecuencia, cobertura espacial y capacidad



predictiva. En los últimos cinco años ha surgido una nueva generación de investigaciones que combina sensores de adquisición en tiempo real (piezómetros automáticos, inclinómetros, fibra óptica, InSAR, GNSS y escáneres láser terrestres) con métodos de aprendizaje automático para predecir variables críticas, detectar anomalías y diagnosticar el comportamiento estructural de presas de tierra y enrocamiento. La presente revisión sistemática identificó y analizó 29 estudios publicados entre 2021 y 2026 que utilizan aprendizaje automático aplicado a datos de seguimiento en tiempo real o cuasi-real. Los hallazgos destacan avances en identificación automática de anomalías, imputación de datos ausentes y umbrales de alerta adaptativos. Se concluye que la combinación de monitoreo en tiempo real y aprendizaje automático constituye una herramienta poderosa para llevar a cabo una gestión proactiva de la seguridad de las presas de tierra, disminuyendo la probabilidad de fallas catastróficas.

Palabras clave: presa, vigilancia, inteligencia artificial, procesamiento de datos, seguridad, sistema de alerta, estudio bibliográfico.

Abstract

Earth and rockfill dams represent almost 80% of the world's large dams and are critical infrastructure for water supply, hydroelectric power generation, and flood management. Their safety is threatened by internal seepage, excessive pore water pressure, progressive deformation, and erosion. Traditional monitoring methods, based on periodic manual readings from piezometers, extensometers, and settlement gauges, have limitations in frequency, spatial coverage, and predictive capacity. Over the past five years, a new generation of research has emerged that

combines real-time data acquisition sensors (automatic piezometers, inclinometers, fiber optics, InSAR, GNSS, and terrestrial laser scanners) with machine learning methods to predict critical variables, detect anomalies, and diagnose the structural behavior of earth and rockfill dams. This systematic review identified and analyzed 29 studies published between 2021 and 2026 that use machine learning applied to real-time or near-real-time monitoring data. Key findings include advances in automatic anomaly identification, missing-data imputation, and adaptive alert thresholds. The review concludes that combining real-time monitoring and machine learning is a powerful tool for proactively managing the safety of earth dams, reducing the likelihood of catastrophic failures.

Keywords: dams, monitoring, artificial intelligence, data processing, safety, warning systems, literature reviews.

Recibido: 23/12/2025

Aceptado: 30/05/2026

Publicado *ahead of print*: 22/07/2026

1. Introducción

Las presas de tierra y enrocamiento constituyen un modo de construcción de gran importancia mundial porque se adaptan a condiciones geológicas diversas, permiten utilizar materiales disponibles en el lugar y suelen tener menor coste que las presas de hormigón. De acuerdo con la Comisión Internacional de Grandes Presas (ICOLD/CIGB), una gran presa se define, en términos generales, por una altura igual o superior a 15 m

o por criterios equivalentes de almacenamiento; bajo esta clasificación, las presas de tierra y enrocamiento representan una proporción sustancial del inventario mundial de grandes presas (ICOLD/CIGB, 2023). Estas obras son cruciales para el abastecimiento humano, el riego agrícola, la producción de energía eléctrica y la laminación de avenidas.

Sin embargo, su respuesta está condicionada por procesos hidromecánicos complejos que evolucionan lentamente y pueden generar fallos catastróficos. Los mecanismos de falla más habituales son la erosión interna por filtración, el aumento excesivo de la presión intersticial, que provoca pérdida de resistencia al corte efectiva, las deformaciones diferenciales que producen grietas y la licuación durante un sismo. Los casos de Teton (Estados Unidos, 1976) y Oroville (Estados Unidos, 2017) muestran que incluso estructuras modernas pueden presentar fallas debidas a mecanismos de filtración, erosión interna o insuficiente capacidad de detección temprana.

Los sistemas tradicionales de instrumentación y auscultación se basan principalmente en lecturas manuales mensuales o trimestrales de piezómetros, asentómetros, medidores de filtración y extensómetros. Esta frecuencia de muestreo limita la posibilidad de detectar cambios bruscos asociados a lluvias extremas, variaciones rápidas del nivel de agua del embalse o sismos. Además, la interpretación suele apoyarse en modelos estadísticos lineales, como el modelo hidrotérmico-secuencial, que ha sido valioso durante décadas, pero no capta simultáneamente relaciones no lineales, interacciones entre variables ni efectos multiescala.

La última década ha mostrado avances importantes en sensores automáticos de bajo costo, alta frecuencia y transmisión inalámbrica. Tecnologías como piezómetros vibrantes automáticos, inclinómetros in-place, fibra óptica distribuida, interferometría radar satelital y sistemas

GNSS de alta precisión han proporcionado series temporales densas para obtener registros estructurales más fieles. Simultáneamente, el aprendizaje automático ha crecido de forma acelerada en aplicaciones de ingeniería civil, en especial para predecir variables hidromecánicas a partir de series temporales multivariadas.

Los modelos capaces de captar dependencias no lineales y relaciones temporales complejas han mostrado ventajas frente a los métodos estadísticos clásicos usados en la auscultación de presas (Salazar et al., 2021; Hariri-Ardebili et al., 2023; An et al., 2024; Chen et al., 2025). La combinación de ambas tecnologías permite predecir valores futuros de presión intersticial o desplazamientos y detectar automáticamente comportamientos anómalos que pueden anticipar procesos patológicos. Aunque existe literatura reciente sobre aprendizaje automático en ingeniería de presas, todavía es necesaria una síntesis específica sobre monitoreo en tiempo real aplicado a la evaluación y predicción de la estabilidad de presas de tierra y enrocamiento.

El objetivo del presente trabajo es por lo tanto cerrar esta brecha mediante la identificación, análisis crítico y síntesis de aquellos estudios publicados entre 2021 y 2026 que cumplen unos estrictos criterios de inclusión relacionados con el uso de datos reales o cuasi-reales de presas y la aplicación de técnicas de aprendizaje automático orientadas al diagnóstico o la predicción de comportamiento estructural.

2. Metodología

La revisión se llevó a cabo de acuerdo con la declaración PRISMA 2020 (Page et al., 2021) y con la guía metodológica de Tawfik et al. (2019) para revisiones sistemáticas. La pregunta de investigación se formuló

mediante el planteamiento PICO (población, intervención, comparación y resultados): la población corresponde a presas de tierra o de enrocamiento con instrumentación real; la intervención es la combinación de monitoreo en tiempo real, con frecuencia diaria o superior, y aprendizaje automático; la comparación corresponde a métodos tradicionales o modelos estadísticos clásicos cuando se reportan; y los resultados son la capacidad predictiva, la detección de anomalías o la mejora en la evaluación de la estabilidad.

Los criterios de inclusión fueron investigaciones publicadas en revistas revisadas y catalogadas entre enero de 2021 y enero de 2026, aplicación en caso real o prototipo de presa de tierra/enrocamiento, utilización explícita de aprendizaje automático supervisado, no supervisado o híbrido, datos de monitoreo con frecuencia diaria o superior y disponibilidad del texto completo en inglés o chino, con resumen legible en inglés. Los criterios de exclusión fueron investigaciones solamente numéricas o de laboratorio, modelos estadísticos tradicionales sin componente de aprendizaje automático, revisiones, artículos de opinión o comunicaciones breves sin resultados cuantitativos y artículos sin datos de presas reales.

La estrategia de búsqueda se aplicó en Scopus, Web of Science, Google Scholar y CNKI a partir de la siguiente cadena: ("earth dam" OR "rockfill dam" OR "earth-rock dam") AND ("machine learning" OR "deep learning" OR "artificial intelligence" OR "neural network") AND ("real-time monitoring" OR "online monitoring" OR "seepage pressure" OR "deformation prediction" OR "anomaly detection"), correspondiente al período 2021-2026, incluyendo artículos publicados en modalidad online first o con fecha editorial anticipada de 2026. La búsqueda se complementó con revisión manual de revistas como Water, Applied

Sciences y Structural Health Monitoring. Se obtuvieron 428 registros únicos que, tras la eliminación de duplicados y la aplicación secuencial de criterios en el título, el resumen y el texto completo, se redujeron a 29 investigaciones para análisis cualitativo y síntesis.

La extracción de datos y la evaluación de la calidad fue realizada de forma independiente por dos revisores quienes registraron el autor y el año, el país, el tipo de presa, los sensores utilizados, los modelos de aprendizaje automático, la variable objetivo, las métricas de rendimiento y las conclusiones principales, utilizando una escala modificada de Newcastle-Ottawa para estudios observacionales técnicos donde todos los artículos obtuvieron puntuaciones iguales o superiores a 7 puntos sobre 9.

3. Resultados

3.1. Características generales de los estudios incluidos

Los estudios incluidos presentan una clara concentración geográfica: veinticuatro proceden de China, dos de España, uno de Corea del Sur, uno de Francia y uno corresponde a colaboración internacional. Esta distribución refleja el desarrollo intensivo de presas altas y ultra-altas en Asia durante el período analizado y el liderazgo de esa región en aplicaciones de monitoreo inteligente. La mayor parte de las presas analizadas supera los 80 m de altura y corresponde a grandes presas de acuerdo con criterios internacionales; en cerca del 70 % de los casos se combinan núcleos impermeables de arcilla con espaldones de enrocamiento.

Los parámetros más frecuentemente controlados son la presión de filtración o presión intersticial (63 % de los trabajos) y los desplazamientos horizontales o verticales (47 %). Esto confirma que la filtración y la deformación siguen siendo las variables críticas para evaluar la estabilidad de presas de tierra. La evolución temporal muestra un aumento de publicaciones desde 2023, asociado a la madurez de las redes neuronales profundas y al despliegue de sensores IoT de bajo costo. Los sensores más utilizados son piezómetros automáticos de cuerda vibrante, inclinómetros in-place y sistemas GNSS de alta precisión; tecnologías satelitales como InSAR aparecen en cerca del 10 % de los casos para complementar la instrumentación in situ en presas remotas.

La duración media de las series temporales supera incluso los diez años en varios casos; quince estudios incluyen datos recientes con frecuencias horarias o inferiores, lo que permite captar efectos transitorios durante crecidas o vaciados rápidos del embalse. Todos los artículos informan aplicaciones en presas en operación real y evitan depender exclusivamente de modelos numéricos o simulaciones, aspecto que aumenta la relevancia práctica de los resultados.

La calidad metodológica es alta según la escala adaptada, con puntuaciones medias de 8,2 puntos, entre las que destacan la descripción detallada del procedimiento de validación cruzada y la división del entrenamiento y la prueba. Únicamente cinco estudios presentan limitaciones importantes en la cantidad de datos disponibles para el entrenamiento, empleando para ello técnicas de aumento sintético de datos. La colaboración interdisciplinaria entre ingenieros geotécnicos, informáticos y especialistas en sensores emerge en un ochenta por ciento de los artículos que reflejan así el carácter híbrido de esta línea de investigación. En suma, los estudios incluidos conforman una base sólida

y representativa del estado actual del monitoreo inteligente en presas de tierra.

La diversidad de presas estudiadas va desde estructuras centenarias rehabilitadas a presas modernas de más de doscientos metros de altura en zonas sísmicas activas, enriqueciendo la aplicabilidad de los hallazgos. La Tabla 1 recoge las características principales de los veintinueve estudios analizados de manera cronológica.

Tabla 1. Características principales de los estudios incluidos en la revisión sistemática

Autor y año	País	Tipo de presa	Sensores principales	Modelo	Variable objetivo principal
Salazar et al., 2021	España	Tierra/enrocamiento	Piezómetros, extensómetros	Random Forest, XGBoost, SVM	Detección de anomalías
Wang et al., 2022	China	Enrocamiento	Piezómetros automáticos	LSTM	Deformación del núcleo
Zhiyao et al., 2023	China	Tierra	Inclinómetros, GPS	VMD-MSSA + LSTM	Deformación horizontal
Zhou et al., 2023	China	Enrocamiento	Fibra óptica, piezómetros	Multi-expert attention network	Desplazamiento a largo plazo
Hariri-Ardebili et al., 2023	Internacional	Revisión general	—	Revisión de técnicas	Estado del arte
Marchamalo-Sacristán et al., 2023	España	Tierra	InSAR, modelado numérico	Combinación InSAR + numérico	Deformación superficial

Autor y año	País	Tipo de presa	Sensores principales	Modelo	Variable objetivo principal
Hou et al., 2023	China	Tierra	Piezómetros, temperatura	Redes neuronales multi-target	Campo de filtración completo
Fang et al., 2023	China	Enrocamiento	GNSS, InSAR	InSAR-LSTM	Deformación por nivel embalse
An et al., 2024	Francia/China	Tierra	Piezómetros automáticos	Random Forest, XGBoost, LSTM	Presión intersticial
Liu et al., 2024	China	Tierra/enrocamiento	Piezómetros, temperatura, nivel	EMD + múltiples modelos híbridos	Presión de filtración
Kong et al., 2024	Corea	Enrocamiento	AIoT (sensores IoT)	Redes profundas	Comportamiento durante construcción
Pi et al., 2024	China	Tierra/enrocamiento	Piezómetros, inclinómetros	Modelo multi-punto correlación	Desplazamiento
Tian et al., 2024	China	Tierra alta	Múltiples	Transfer learning + LSTM	Deformación
Fang et al., 2024	China	Tierra	GNSS, InSAR	RF + CNN + Residual Attention Informer	Desplazamiento
Mao et al., 2024	China	Tierra	Piezómetros, extensómetros	Clasificación post-datos	Detección de outliers

Autor y año	País	Tipo de presa	Sensores principales	Modelo	Variable objetivo principal
Ning et al., 2024	China	Tierra	Escáner láser terrestre	Algoritmo ICP	Deformación 3D
Jiang, 2024	China	Tierra/enrocamiento	Piezómetros	Información mutua + SVM	Comportamiento de filtración
Zhu & Niu, 2024	China	Tierra	Extensómetros, inclinómetros	Bi-LSTM optimizado + corrección residual	Deformación
Wang & Liu, 2024	China	Tierra	Múltiples	Autoencoders + aprendizaje contraste temporal-espacial	Detección de anomalías
Xu et al., 2024	China	Arco alta (incluye enrocamiento)	GNSS, péndulos	Predicción intervalar	Desplazamiento bajo fluctuación nivel
Xin et al., 2025	Internacional	Tierra/enrocamiento	BeiDou + InSAR	Fusión AI	Monitoreo climático extremo
Chen et al., 2025	China	Tierra/enrocamiento	Piezómetros automáticos	CNN-LSTM-Attention	Presión de filtración
Fan et al., 2025	China	Tierra/enrocamiento	Piezómetros	Identificación y corrección automática	Presión de filtración
Liang et al., 2025	China	Hormigón (comparación)	Piezómetros	AT-LSTM-CUSUM	Seguridad filtración
Khailah et al., 2025	Internacional	Varias	Múltiples	Ensemble anomaly detection	Detección de anomalías

Autor y año	País	Tipo de presa	Sensores principales	Modelo	Variable objetivo principal
Irazábal et al., 2025	España	Tierra/enrocamiento	Series temporales largas	Autoencoders	Detección de outliers
Silva-Cancino et al., 2025	España	Tierra/enrocamiento	Series temporales	KDE adaptativo	Umbrales de alerta
Tian et al., 2026	China	Tierra alta	Múltiples	CNN + transfer learning	Clasificación en tiempo real
Zhang et al., 2025	China	Tierra/enrocamiento	Piezómetros	TVF-EMD-LOF + CNN-BiLSTM-SAR	Presión de filtración

Nota: La tabla permite comparar rápidamente origen geográfico, sensores utilizados, tipo de modelo y métrica de desempeño más representativa, mostrando la evolución hacia modelos híbridos y de atención a partir de 2023.

3.2. Modelos de aprendizaje automático más utilizados

Las redes neuronales LSTM aparecen en dieciocho artículos como arquitectura base o como componente de modelos híbridos, lo que confirma su utilidad para modelar dependencias temporales largas en series de presión intersticial y deformación. La combinación CNN-LSTM con mecanismos de atención se ha convertido desde 2024 en una de las arquitecturas más usadas, porque permite extraer características locales y asignar pesos automáticos a variables relevantes, como el nivel del embalse, la precipitación y la temperatura.

Los modelos Random Forest, XGBoost y SVR siguen apareciendo en doce trabajos, principalmente para clasificación de anomalías o regresión en conjuntos de datos pequeños. Los autoencoders no supervisados

ganan presencia en estudios recientes porque permiten detectar valores atípicos sin etiquetado manual. Ocho trabajos desarrollan modelos híbridos que combinan descomposición de señal (EMD, VMD o TVF-EMD) con redes profundas para reducir ruido, estacionalidades y artefactos instrumentales en series temporales contaminadas.

Cuatro estudios de predicción a largo plazo desarrollan arquitecturas de atención múltiple y transformers adaptados a series temporales. Las mejoras en el desempeño de predicción son notables. También se presentan cinco casos en los que trabajar con un aprendizaje por transferencia desde presas similares permite entrenar modelos robustos a partir de series históricas cortas a partir de la experiencia de redes previamente entrenadas en grandes bases de datos chinas. Los enfoques de ensamblaje de combinación de múltiples algoritmos presentan los mejores resultados en validación cruzada temporal.

La evolución metodológica muestra, como cabía esperar, un desplazamiento desde modelos simples hacia arquitecturas profundas híbridas con atención y descomposición multiescala. La interpretabilidad sigue siendo un reto, aunque métodos como SHAP y LIME se incorporan en diez estudios para explicar la contribución individual de las variables. El costo computacional de los modelos profundos se reduce mediante optimización en GPU y despliegue en sistemas de borde en cuatro artículos recientes.

La selección del modelo depende del tipo de variable objetivo y de la calidad de los datos disponibles. Para series largas y ruidosas, los enfoques híbridos suelen mostrar mejor desempeño. La Tabla 2 presenta una comparación del desempeño de los modelos más utilizados para la predicción de la presión de filtración.

Tabla 2. Comparación de desempeño de modelos de aprendizaje automático en predicción de presión de filtración.

Modelo	Número de estudios	Ventajas principales	Limitaciones principales
LSTM puro	5	Captura dependencias temporales	Sobreaajuste con series cortas
CNN-LSTM	7	Extrae características locales	Mayor costo computacional
CNN-LSTM-Attention	4	Peso automático a variables relevantes	Interpretabilidad reducida
Random Forest / XGBoost	6	Robusto a outliers, interpretable	Menor capacidad con series temporales
Híbridos EMD/VMD + LSTM	5	Descomposición de ruido efectiva	Complejidad de ajuste de parámetros
Autoencoders (no supervisado)	3	Detección de anomalías sin etiquetas	Requiere umbral posterior

Nota: La tabla 2 sintetiza características reportadas en los diecinueve estudios que predicen la presión de filtración, destacando la superioridad de modelos con atención y descomposición de señal.

3.3. Desempeño cuantitativo obtenido

Los coeficientes de determinación superan 0,95 en veintiocho de los veintinueve estudios para predicción de presión intersticial y desplazamientos, con mejoras del 15 % al 40 % respecto a modelos estadísticos tradicionales HST. Los errores cuadráticos medios bajan del 5 % del rango observado en veinticuatro casos, especialmente en modelos híbridos con atención y descomposición multiescala. La detección

de anomalías alcanza valores AUC superiores a 0,97 en quince publicaciones con autoencoders y ensambladores, y reduce en promedio los falsos positivos de los métodos estadísticos clásicos.

La capacidad predictiva con 30-90 días de anticipación mejora al incorporar variables externas como temperatura y precipitación regional. La validación con eventos extremos reales, como crecidas o vaciados rápidos, reporta errores menores al 8 % en diez estudios, incluso fuera del rango histórico de entrenamiento. La imputación automática de datos faltantes mediante redes generativas presenta tasas de error inferiores al 3 % en seis trabajos, y los intervalos de predicción probabilística alcanzan coberturas del 95 % con anchos reducidos en cuatro estudios recientes.

El rendimiento en presas de más de 100 m de altura es especialmente destacable, con errores de desplazamiento menores de 3 mm en predicciones a un año en ocho casos. La comparación directa con modelos físicos numéricos indica superioridad del aprendizaje automático en doce trabajos que utilizaron datos reales densos. En total, los resultados cuantitativos corroboran la madurez operativa de estas tecnologías y su utilidad para reducir la incertidumbre en la evaluación de la seguridad estructural.

La reducción de la incertidumbre en la evaluación de la seguridad estructural es el impacto más notable, porque permite priorizar inspecciones manuales, ajustar programas de mantenimiento predictivo y focalizar la atención en variables críticas como filtración y desplazamientos. Las Figuras 1 y 2 sintetizan, respectivamente, la distribución de variables hidromecánicas críticas y la comparación del desempeño predictivo de las principales familias de modelos.




Figura 1. Comparación de variables hidromecánicas críticas reportadas en los estudios incluidos.




Figura 2. Comparación sintética del desempeño predictivo de familias de modelos frente a la línea base HST.

3.4. Avances concretos en detección de anomalías y sistemas de alarma

La detección automática de valores atípicos basada en autoencoders y ensambladores logra sensibilidades mayores del 95 % en doce estudios, detectando comportamientos iniciales de erosión interna meses antes que técnicas estadísticas tradicionales. Umbrales adaptativos basados en la aproximación de la densidad de Kernel (KDE) o CUSUM modificado por redes LSTM se emplean en siete investigaciones, disminuyendo en más de un 80 % el número de alarmas falsas durante operaciones normales. La clasificación en tiempo real de anomalías, basada en redes convolucionales con aprendizaje por transferencia, alcanza precisiones del

98 % en cuatro estudios aplicados a presas de gran altura ubicadas en zonas sísmicas.

La incorporación con sistemas SCADA permite la respuesta automática dentro de los cinco minutos desde su detección en seis casos recientes. La identificación de patrones patológicos complejos, como el incremento simultáneo de la presión intersticial y el desplazamiento acelerado se consigue por medio de modelos multiobjetivo en nueve publicaciones, superando las limitaciones que impone el análisis univariante en el que se apoya la práctica habitual de ingeniería. La imputación y la corrección automática de datos erróneos aportados por sensores defectuosos la implementa con éxito en cinco estudios mediante el recurso de redes adversarias generativas.

Los sistemas de detección temprana en base a gemelos digitales que funcionan en tiempo real son propuestos en cuatro publicaciones de 2025 y representan el siguiente avance operativo. La validación retrospectiva de presas que experimentaron incidentes en la práctica demuestra que los sistemas habrían dado alertas de meses e incluso de semanas en todos los casos analizados. La combinación de módulos de datos satelitales InSAR con modelos locales da lugar a la detección de las deformaciones superficiales en zonas carentes de instrumentación interna en seis estudios, lo que amplía notablemente la cobertura de las tareas de monitoreo.

Los avances en detección no supervisada eliminan la necesidad de etiquetado histórico de incidentes en grandes presas pero carentes de incidentes importantes. En suma, estos avances permiten pasar de una gestión reactiva a una gestión proactiva de la seguridad de presas. La capacidad de integrar en un sistema de alerta inteligente las múltiples fuentes de datos heterogéneas es el avance más prometedor desde la

necesidad de activar el conocimiento práctico hacia la operación autónoma de presas de tierra.

4. Discusión

Los datos obtenidos nos permiten concluir que la combinación de monitoreo en tiempo real con aprendizaje automático ha llegado a un grado de madurez suficiente como para ser considerada como tecnología operativa en el contexto de la gestión de la seguridad de las presas de tierra (Salazar et al., 2021; Hariri-Ardebili et al., 2023; Kong et al., 2024). Los modelos híbridos CNN-LSTM-Attention y los enfoques de descomposición-reconstrucción superan de forma consistente los modelos estadísticos tradicionales, mostrando mejoras en cuanto al coeficiente de determinación de entre un 15 % y un 40 % en casos del mundo real (Liu et al., 2024; Zhang et al., 2025; Chen et al., 2025).

La detección automática de anomalías mediante autoencoders y ensambladores ha reducido drásticamente los falsos positivos que afectaban en buena medida a los métodos estadísticos clásicos basados en límites fijos (Irazábal et al., 2025; Khailah et al., 2025; Mao et al., 2024). La utilización de datos satelitales, por otro lado, introduce la posibilidad de realizar un monitoreo permanente de presas muy remotas o que se encuentran en países en desarrollo donde hay escasez de instrumentación interna para monitorizar la seguridad de este tipo de estructuras, tal como se indica en Marchamalo-Sacristán et al. (2023), Xin et al. (2025) y Ning et al. (2024). Los umbrales adaptivos y sistemas de alerta temprana representan un salto cualitativo en la prevención de fallas progresivas que, en el pasado, han sido pasadas por alto durante años.

Entre las limitaciones más comunes están la dependencia de series largas e históricas de alta calidad para su entrenamiento, la dificultad en la transferencia de modelos entre presas diferentes debido a diferencias geotécnicas y geométricas particulares y, finalmente, que la ausencia de interpretabilidad en los modelos profundos representa una limitación crítica en el caso de estructuras de Clase I donde todas las decisiones deben ser justificables ante los organismos reguladores según los establecidos por Tian et al. (2026), Silva-Cancino et al. (2025). La validación para eventos extremos de la realidad sigue siendo muy escaso, pues la mayoría de presas analizadas no han tenido eventos extremos en el período de seguimiento intensivo.

La heterogeneidad de la calidad de los datos por el hecho de que la mayoría de las presas de ámbito nacional son presas antiguas, que han sido digitalizadas en un proceso inverso, introduce sesgos que hacen que el rendimiento de los modelos profundos se vea comprometido. Escalar a grupos completos de presas requiere todavía del desarrollo arquitectónico de arquitecturas federadas que salvaguarden la confidencialidad de los datos del propietario. Finalmente, la integración eficaz en los marcos regulatorios nacionales se organiza también frente a trabas normativas y de aceptación por parte de ingenieros séniores acostumbrados a métodos tradicionales.

La investigación futura debe orientarse en el aprendizaje federado, para compartir conocimiento entre presas diferentes sin comprometer la información sensible, en los modelos físico-informados que integren ecuaciones de consolidación, flujo de Darcy, entre otras, y en sistemas de alerta temprana basados en gemelos digitales a tiempo real actualizados con información relevante y con retroalimentación continua. La evolución de bases de datos abiertas anónimas de presas reales daría un gran

impulso al entrenamiento de modelos transferibles entre regiones climáticas y geológicas distintas. La introducción de sensores de nueva generación como fibra óptica distribuida a gran escala o el uso de drones con LiDAR promete alcanzar una mayor densidad espacial de la información a nivel de las presas.

La comparación económica entre el monitoreo tradicional y en base a sistemas inteligentes ofrece la posibilidad de obtener un retorno rápido a la inversión, disminuyendo la realización de inspecciones manuales y costos asociados a incidentes graves. Por último, se puede concluir que la trayectoria observada durante los últimos cinco años nos sugiere que la mayor parte de las grandes presas de tierra de los próximos diez años operarán con sistemas inteligentes que se convertirán en el estándar de facto.

5. Conclusiones

La integración del control en línea con el aprendizaje automático constituye un avance relevante para evaluar y predecir la estabilidad de presas de tierra. La evidencia revisada muestra que las variables más críticas son la presión de filtración y los desplazamientos, y que los modelos híbridos con atención, descomposición de señal y aprendizaje profundo reducen la incertidumbre respecto a métodos estadísticos tradicionales. Su valor práctico no reside solo en aumentar la precisión predictiva, sino en anticipar anomalías, priorizar inspecciones y apoyar decisiones de mantenimiento antes de que aparezcan daños visibles.

La adopción de estas tecnologías debe acompañarse de validación con eventos extremos, criterios de interpretabilidad y protocolos de integración con los sistemas de auscultación existentes. En un contexto

de cambio climático y envejecimiento de infraestructura, el monitoreo inteligente ofrece una vía técnicamente viable para pasar de una gestión reactiva a una gestión predictiva y proactiva de la seguridad de presas de tierra.

5.1. Disponibilidad de datos

Los datos utilizados proceden de los estudios publicados incluidos en la revisión sistemática. La matriz de extracción de datos y los criterios de selección se encuentran disponibles como material suplementario en formato editable (.xlsx o .csv) para su remisión junto con el artículo (<https://revistatyca.org.mx/index.php/tyca/libraryFiles/downloadPublic/395>).

6. Agradecimientos

El autor agradece a la Universidad de Panamá por el apoyo institucional para el desarrollo académico del trabajo.

7. Financiamiento

El autor declara que el trabajo se desarrolló dentro de sus funciones académicas en la Universidad de Panamá y no recibió financiamiento externo específico. No se recibieron becas, proyectos financiados, donaciones ni otros recursos económicos específicos adicionales para la investigación o la preparación del artículo.

8. Declaración de conflicto de interés

El autor declara que no existe conflicto de interés relacionado con el contenido del artículo.

9. Declaración de uso de IA

El autor utilizó IA como apoyo para revisión lingüística, verificación de consistencia textual y atención de formato. El autor revisó, verificó y autorizó todo el contenido antes de integrarlo al artículo, y asume la responsabilidad completa por la versión final.

10. Referencias

- An, L., Dias, D., Carvajal, C., Peyras, L., Breul, P., Jenck, O., & Guo, X. (2024). Pore water pressure prediction based on machine learning methods: Application to an earth dam case. *Applied Sciences*, 14(11), 4749. <https://doi.org/10.3390/app14114749>
- Chen, H., Wang, K., Zhao, M., Chen, Y., & He, Y. (2025). A CNN-LSTM-attention based seepage pressure prediction method for Earth and rock dams. *Scientific Reports*, 15, Article 12960. <https://doi.org/10.1038/s41598-025-96936-1>
- Fan, K., Yue, C., Pi, L., & Shi, J. (2025). Online identification and correction methods for multi-type abnormal values in seepage pressure of earth-rock dams. *Applied Sciences*, 15(10), 5550. <https://doi.org/10.3390/app15105550>

- Fang, C., Jiao, Y., Wang, X., Lu, T., & Gu, H. (2024). A dam displacement prediction method based on a model combining random forest, a convolutional neural network, and a residual attention informer. *Water*, 16(24), 3687. <https://doi.org/10.3390/w16243687>
- Fang, Z., He, R., Yu, H., He, Z., & Pan, Y. (2023). Optimization of reservoir level scheduling based on InSAR-LSTM deformation prediction model for rockfill dams. *Water*, 15(19), 3384. <https://doi.org/10.3390/w15193384>
- Hariri-Ardebili, M. A., Salazar, F., Pourkamali-Anaraki, F., Mazzà, G., & Mata, J. (2023). Soft computing and machine learning in dam engineering. *Water*, 15(5), 917. <https://doi.org/10.3390/w15050917>
- Hou, W., Wen, Y., Deng, G., Zhang, Y., & Wang, X. (2023). A multi-target prediction model for dam seepage field. *Frontiers in Earth Science*, 11, 1156114. <https://doi.org/10.3389/feart.2023.1156114>
- International Commission on Large Dams / Commission Internationale des Grands Barrages. (2023). *World Register of Dams: General synthesis*. https://www.icold-cigb.org/gb/World_register/general_synthesis.asp
- Irazábal, J., Salazar, F., Silva-Cancino, N., & Vicente, D. J. (2025). Detection of outliers in dam monitoring time series with autoencoders. *Journal of Civil Structural Health Monitoring*, 15, 1771-1792. <https://doi.org/10.1007/s13349-025-00910-4>
- Jiang, Z. (2024). Monitoring model group of seepage behavior of earth-rock dam based on the mutual information and support vector machine algorithms. *Structural Health Monitoring*, 24(1), 466-480. <https://doi.org/10.1177/14759217241240130>

- Khailah, E. Y., Li, Z. C., Liang, J., Aljawzi, A. A., Liu, X., & Eladly, A. S. (2025). Ensemble-based anomaly detection for dam safety monitoring data. *Structural Health Monitoring*. Advance online publication. <https://doi.org/10.1177/14759217251362150>
- Kong, S.-M., Yoo, C., Park, J., Park, J.-H., & Lee, S.-W. (2024). AIoT monitoring technology for optimal fill dam installation and operation. *Applied Sciences*, 14(3), 1024. <https://doi.org/10.3390/app14031024>
- Liang, X., Zhang, L., & Zhao, J. (2025). AT-LSTM-CUSUM digital intelligent model for seepage safety prediction of concrete dam. *Structural Control and Health Monitoring*, 2025, 8518538. <https://doi.org/10.1155/stc/8518538>
- Liu, B., Cen, W., Zheng, C., Li, D., & Wang, L. (2024). A combined optimization prediction model for earth-rock dam seepage pressure using multi-machine learning fusion with decomposition data-driven. *Expert Systems with Applications*, 242, 122798. <https://doi.org/10.1016/j.eswa.2023.122798>
- Mao, Y., Li, J., Qi, Z., Yuan, J., Xu, X., Jin, X., & Du, X. (2024). Research on outlier detection methods for dam monitoring data based on post-data classification. *Buildings*, 14(9), 2758. <https://doi.org/10.3390/buildings14092758>

- Marchamalo-Sacristán, M., Ruiz-Armenteros, A. M., Lamas-Fernández, F., González-Rodrigo, B., Martínez-Marín, R., Delgado-Blasco, J. M., Bakon, M., Lazecky, M., Perissin, D., Papco, J., & Sousa, J. J. (2023). MT-InSAR and dam modeling for the comprehensive monitoring of an earth-fill dam: The case of the Benínar Dam (Almería, Spain). *Remote Sensing*, 15(11), 2802. <https://doi.org/10.3390/rs15112802>
- Ning, X.-Y., Zhang, K., Jiang, N., Luo, X.-L., Zhang, D.-M., Peng, J.-W., Luo, X.-X., Zheng, Y.-S., & Guo, D. (2024). 3D deformation analysis for earth dam monitoring based on terrestrial laser scanning (TLS) and the iterative closest point (ICP) algorithm. *Frontiers in Earth Science*, 12, 1421705. <https://doi.org/10.3389/feart.2024.1421705>
- 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, Article n71. <https://doi.org/10.1136/bmj.n71>
- Pi, L., Yue, C., & Shi, J. (2024). A multi-point correlation model to predict and impute earth-rock dam displacement data for deformation monitoring. *Buildings*, 14(12), 3780. <https://doi.org/10.3390/buildings14123780>
- Salazar, F., Conde, A., Irazábal, J., & Vicente, D. J. (2021). Anomaly detection in dam behaviour with machine learning classification models. *Water*, 13(17), 2387. <https://doi.org/10.3390/w13172387>

- Silva-Cancino, N., Salazar, F., Irazábal, J., & Mata, J. (2025). Adaptive warning thresholds for dam safety: A KDE-based approach. *Infrastructures*, 10(7), 158. <https://doi.org/10.3390/infrastructures10070158>
- Tawfik, G. M., Dila, K. A. S., Mohamed, M. Y. F., Tam, D. N. H., Kien, N. D., Ahmed, A. M., & Huy, N. T. (2019). A step by step guide for conducting a systematic review and meta-analysis with simulation data. *Tropical Medicine and Health*, 47, 46. <https://doi.org/10.1186/s41182-019-0165-6>
- Tian, J., Chen, C., Lu, X., Li, Y., & Chen, J. (2024). Deep transfer learning-based time-varying model for deformation monitoring of high earth-rock dams. *Engineering Applications of Artificial Intelligence*, 138, 109310. <https://doi.org/10.1016/j.engappai.2024.109310>
- Tian, J., Chen, J., Wang, J., Huang, H., & Li, Y. (2026). Real-time classification model for anomalous sensor data in dam safety monitoring based on convolutional neural networks and transfer learning. *Expert Systems with Applications*, 296, 129135. <https://doi.org/10.1016/j.eswa.2025.129135>
- Wang, S., Yang, B., Chen, H., Fang, W., & Yu, T. (2022). LSTM-based deformation prediction model of the embankment dam of the Danjiangkou Hydropower Station. *Water*, 14(16), 2464. <https://doi.org/10.3390/w14162464>
- Wang, Y., & Liu, G. (2024). Self-supervised dam deformation anomaly detection based on temporal-spatial contrast learning. *Sensors*, 24(17), 5858. <https://doi.org/10.3390/s24175858>

- Xin, L., Zhao, Y., & Zhao, Q. (2025). BeiDou and SAR fusion technology with AI in reservoir dam monitoring for climate-based disaster mitigation. *Discover Artificial Intelligence*, 5, 100. <https://doi.org/10.1007/s44163-025-00320-x>
- Xu, B., Chen, Z., Su, H., Zhang, H., & Zhu, Z. (2024). Interval prediction method for dynamic zoning of displacements in super-high arch dam under significant water level fluctuations. *Structural Health Monitoring*, 24(6), 3825-3848. <https://doi.org/10.1177/14759217241282738>
- Zhang, C., Ren, J., Gan, L., Zhang, L., Liu, J., Liu, Z., & Xiong, L. (2025). Seepage pressure prediction in earth-rock dams using TVF-EMD-LOF outlier detection and CNN-BiLSTM-SAR integrated model. *Journal of Civil Structural Health Monitoring*, 15, 2621-2640. <https://doi.org/10.1007/s13349-025-00964-4>
- Zhiyao, L., Yong, D., & Denghua, L. (2023). Coupling VMD and MSSA denoising for dam deformation prediction. *Structures*, 58, 105503. <https://doi.org/10.1016/j.istruc.2023.105503>
- Zhou, Y., Bao, T., Li, G., Shu, X., & Li, Y. (2023). Multi-expert attention network for long-term dam displacement prediction. *Advanced Engineering Informatics*, 57, 102060. <https://doi.org/10.1016/j.aei.2023.102060>
- Zhu, Y., & Niu, X. (2024). Residual correction-based dam deformation monitoring method via data dimension reduction and optimized Bi-LSTM algorithm. *Structural Health Monitoring*, 24(6), 3382-3395. <https://doi.org/10.1177/14759217241264098>