
Aplicaciones de la teledetección y los Sistemas de Información Geográfica en la delimitación de inundaciones y la cuantificación de daños a la infraestructura urbana: una revisión sistemática

Anyi Liliana Rincón Benjumea

Yeison Castañeda Castaño

Seleccione tipo de documento para optar al título de Especialistas en Medio Ambiente y Geoinformática

Asesor

Juan José García Duque, Magíster (MSc) en Ingeniería Ambiental

Universidad de Antioquia

Facultad de Ingeniería

Especialización en Medio Ambiente y Geoinformática

Medellín, Antioquia, Colombia

2025

Cita	(Rincón Benjumea & Castañeda Castaño, 2025)
Referencia	Rincón Benjumea, A. L., & Castañeda Castaño, Y. (2025). Aplicaciones de la teledetección y los Sistemas de Información geográfica en la delimitación de inundaciones y la cuantificación de daños a la infraestructura urbana: una revisión sistemática [Trabajo de grado especialización]. Universidad de Antioquia, Medellín, Colombia.
Estilo APA 7 (2020)	



Especialización en Medio Ambiente y Geoinformática , Cohorte XX.

Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Tabla de contenido

Resumen	7
Abstract	8
Introducción	9
Objetivos	10
Metodología	11
Resultados del proceso de revisión bibliográfica	12
Resultados	16
Herramientas de inteligencia artificial	17
Machine Learning	17
Deep Learning.....	18
Métodos basados en estadística y segmentación.....	19
Método probabilístico/ Enfoque Bayesiano	20
Métodos de Ensamblaje	21
Índices espectrales.....	21
Internet of Things (IoT), sensores	22
Drones, UAVs, LiDAR	23
Imágenes satelitales con otros instrumentos	24
Síntesis metodológica.....	25
Discusión.....	46
Inundaciones en contextos urbanos	47
Sensores remotos aplicados al estudio de inundaciones	48
Sistemas de Información Geográfica (SIG) en el análisis de afectaciones urbanas.....	49
Infraestructura urbana y afectaciones.....	51

Conclusiones	54
Referencias	57

Lista de tablas

Tabla 1. Métricas de evaluación.....	16
Tabla 2. Metodologías que utilizan sensores remotos integrado a SIG para la detección de inundaciones en zonas urbanas.	26

Lista de figuras

Figura 1. Proceso realizado con la metodología Proknow-C.....	12
Figura 2. Número de publicaciones por revista.....	13
Figura 3. Número de publicaciones por año.	14
Figura 4. Número de estudios sobre inundaciones urbanas.	15

Siglas, acrónimos y abreviaturas

AHP	Analytic Hierarchy Process
AUC–ROC.	Area Under the Curve – Receiver Operating Characteristic
AWEI	Automated Water Extraction Index
BASNet	Boundary-Aware Salient Object Detection Network
CD	Change Detection
CNN	Convolutional Neural Network
DEM/MDE	Modelo Digital de Elevación
DII	Depth Inundation Index
DL	Deep Learning
EVI	Enhanced Vegetation Index
GAN	Generative Adversarial Network
HAND	Height Above Nearest Drainage
IoT	Internet of Things
IoU	Intersection over Union
KC	Kappa Coefficient
LSTM	Long Short-Term Memory
ML	Machine Learning
MLC	Maximum Likelihood Classification
MLP	Multilayer Perceptron
MNDWI	Modified Normalized Difference Water Index
NDMI	Normalized Difference Moisture Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NDFI	Normalized Difference Flood Index
OA	Overall Accuracy
RF	Random Forest
RGB	Red, Green, Blue

RI	Ratio Image
RS	Remote Sensing
DII	Difference Image Index
RNN	Recurrent Neural Network
SAR	Synthetic Aperture Radar
SVM	Support Vector Machine
WSN	Wireless Sensor Networks

Resumen

La teledetección y los Sistemas de Información Geográfica (SIG) se consolidan como herramientas fundamentales para la delimitación y gestión de inundaciones. Debido a la variación climática y el crecimiento acelerado de las ciudades, las inundaciones han incrementado en los últimos años, y se espera que esta tendencia continúe, posiblemente con eventos más extremos, convirtiéndose en una amenaza crítica. Con base en lo anterior, el presente estudio tiene como objetivo realizar una revisión sistemática de la literatura basada en la metodología ProKnow-C para analizar enfoques que tiendan a brindar soluciones.

El portafolio bibliométrico, está conformado por 51 artículos publicados entre 2020 y 2025, de los que se identifica la tendencia en el uso de algoritmos que utilizan inteligencia artificial, especialmente modelos de Machine Learning y Deep Learning, debido a su capacidad para integrar múltiples datos y mejorar la precisión del mapeo en contextos urbanos. Aunque la teledetección es una herramienta clave, aun se presentan desafíos relacionados con la complejidad de detección y mapeo de estas zonas; entre otros, factores como la resolución espacialtemporal y la nubosidad.

Asimismo, se identificó un avance en integración multifuente, combinando inteligencia artificial con datos más tradicionales como DEM, modelos hidrológicos, complementación entre sensores (SAR+ óptico) y modelación física. Se encuentran tecnologías emergentes como el uso de IoT, LiDAR, UAVs y plataformas de procesamiento de datos como Google Earth Engine, lo que facilita la detección rápida ante ocurrencia de eventos y la adaptabilidad a otros sitios.

Palabras clave: Inundación urbana, SIG, Teledetección, infraestructura urbana, delimitación de inundaciones.

Abstract

Remote sensing and Geographic Information Systems (GIS) are becoming established as fundamental tools for flood delineation and management. Due to climate change and rapid urban growth, flooding has increased in recent years, and this trend is expected to continue, possibly with more extreme events, becoming a critical threat. Based on the above, this study aims to conduct a systematic review of the literature based on the ProKnow-C methodology to analyze approaches that tend to provide solutions.

The bibliometric portfolio consists of 51 articles published between 2020 and 2025, which identify a trend in the use of algorithms that employ artificial intelligence, especially machine learning and deep learning models, due to their ability to integrate multiple data sets and improve mapping accuracy in urban contexts. Although remote sensing is a key tool, challenges remain related to the complexity of these areas, spatial and temporal resolution, and cloud cover.

Likewise, progress was identified in multi-source integration, combining artificial intelligence with more traditional data such as DEM, hydrological models, sensor complementarity (SAR+ optical), and physical modeling. Emerging technologies such as the use of IoT, LiDAR, UAVs, and data processing platforms such as Google Earth Engine are facilitating rapid detection of events and adaptability to other sites.

Keywords: urban flood, GIS, remote sensing, urban infrastructure, flood delineation.

Introducción

Las inundaciones urbanas se han convertido en unos de los desastres naturales con mayor capacidad de interrumpir la vida diaria de las zonas urbanas. Debido a la combinación de variabilidad climática, urbanización rápida, y la ocupación de áreas naturalmente expuestas su frecuencia y severidad van en aumento, de hecho, como se evidencia en varios estudios, los desastres por inundaciones son los responsables de aproximadamente el 47% de la ocurrencia global de desastres hidrometeorológicos (Sajjad et al., 2025), afectando tanto zonas rurales como zonas densamente urbanizadas, donde el aumento de permeabilidad está asociado con un mayor escurrimiento y una capacidad de drenaje reducida.

Los enfoques convencionales de modelado hidrológico han proporcionado visiones útiles para entender la dinámica del agua, sin embargo, presentan limitaciones para su aplicación en zonas urbanas complejas, además no son la alternativa más eficiente para el mapeo rápido por sus altos requisitos y carga computacional, lo que limita detecciones tempranas y el despliegue de acciones ante la ocurrencia de desastres. Ante estas limitaciones, ha surgido la teledetección como una herramienta esencial, ya que se vuelve crucial en episodios extremos donde la observación óptica está limitada; así las cosas, algunos estudios reportan que el uso de sensores de radar, como Sentinel-1 son altamente efectivos, especialmente porque no depende de las nubes y pueden detectar inundaciones en condiciones atmosféricas desfavorables (Tanim et al., 2022).

Así mismo, se ha consolidado una tendencia marcada hacia la integración de metodologías de aprendizaje automático (machine learning) y aprendizaje profundo (Deep learning) con el fin de mejorar la identificación de áreas inundadas. Autores como Bai et al., (2021) observan que modelos como BASNet permiten la detección de aguas permanentes y temporales sin requerir datos multitemporales o preprocesamientos complejos, reduciendo la dependencia a información e incrementando el nivel de automatización. De manera similar, arquitecturas como U-Net han mostrado precisiones superiores al 90% en la segmentación de áreas inundadas en entornos urbanos (Mohamadiazar et al., 2024). Esto demuestra que los cambios metodológicos hacia enfoques más flexibles, lleva a menos dependencia de datos etiquetados y una mayor capacidad para reconocer patrones complejos en superficies urbanas heterogéneas.

Los territorios urbanos, no obstante, presentan desafíos específicos; los edificios generan sombras, rebotes dobles y variaciones abruptas en la intensidad, lo que dificulta distinguir el agua de las superficies reflectantes o lisas. En tales casos, se establece que las áreas urbanas presentan desafíos significativos debido a los efectos de sombra y rebote doble producidos por los edificios (Wu et al., 2023). Estos desafíos pueden ser la razón por la cual diferentes estudios de investigación abogan por la integración de sensores ópticos y SAR y/o métodos híbridos o probabilísticos que combinan diferentes modos de evidencia (Zhu et al., 2025).

Las herramientas SIG complementan estos métodos de recolección de datos al integrar información topográfica, hidrológica, demográfica e infraestructura. Autores como Sajjad et al., (2025) mencionan que la fusión entre datos de sensores remotos y SIG permiten análisis espaciales más robustos para la toma de decisiones y la gestión del riesgo. Estos enfoques de integración permiten que la base no sea solo para la delimitación precisa de áreas inundadas sino también para la

identificación de zonas vulnerables, rutas críticas, áreas construidas afectadas y variación del uso del suelo, que son indicadores críticos de acción oportuna y planificación adecuada.

A pesar de los avances, existen deficiencias metodológicas; la investigación comparativa destaca inconvenientes como la falta de series temporales de calidad (Zhu et al., 2025), la dependencia de modelos que fueron entrenados en diferentes contextos (Arias Choquehuanca et al., 2023; Bai et al., 2021), la escasa disponibilidad de información socioeconómica confiable (An et al., 2022), la nubosidad en los sensores ópticos que afecta la clasificación y la dificultad para validar los resultados obtenidos en el campo. Como sugieren (Kulk et al., 2023) todavía es necesario desarrollar algoritmos capaces de desempeñarse mejor bajo condiciones atmosféricas adversas y en territorios con alta complejidad urbana.

En coherencia con este propósito, el objetivo de esta monografía es analizar con una revisión sistemática de literatura científica, las diferentes metodologías en teledetección y Sistemas de Información Geográfica en entornos urbanos y dirigidas a la delimitación de inundaciones, cuantificación de daños a infraestructuras urbanas, la integración de satélites, técnicas de aprendizaje automático y análisis espacial. A partir de la matriz bibliométrica obtenida, se analizan las tendencias metodológicas, los desarrollos recientes, las deficiencias y las oportunidades potenciales para mejorar la utilización de los SIG y los datos satelitales en la gestión del riesgo de inundaciones. Esta revisión busca aportar un marco conceptual actualizado y crítico que sirva de insumo base para futuras aplicaciones, particularmente en entornos urbanos que tienen desafíos técnicos, ambientales y sociales que convergen a gran escala.

Objetivos

3.1 Objetivo general

Analizar mediante una revisión sistemática de literatura científica, las metodologías basadas en teledetección y Sistemas de Información Geográfica utilizadas en la delimitación de inundaciones y en la cuantificación de daños en infraestructura urbana.

3.2 Objetivos específicos

- Establecer criterios de búsqueda, selección y exclusión de fuentes para la construcción del portafolio bibliográfico sobre aplicaciones de teledetección y SIG en la gestión de inundaciones urbanas.
- Identificar las metodologías documentadas en la literatura científica para la delimitación de inundaciones y la evaluación de sus efectos sobre la infraestructura urbana.
- Analizar las tendencias, limitaciones y alcances de las metodologías identificadas, destacando sus aportes y vacíos en el estudio de inundaciones en entornos urbanos.

Metodología

Con el objetivo de analizar las aplicaciones de la teledetección y los Sistemas de Información Geográfica (SIG) en la detección de inundaciones y la identificación de afectaciones en infraestructura urbana a causa de estos eventos, se realiza un rastreo bibliográfico utilizando la metodología Proknow- C (Knowledge Development Process Constructivist), que hace referencia a un modelo desarrollado por el Laboratorio de Metodologías Multicriterio de Apoyo a la Toma de Decisiones Constructivistas (LabMCDA) de la Universidad Federal de Santa Catarina- Brasil para la construcción de conocimiento conformado por filtros progresivos a partir de criterios preestablecidos, que tiene como objetivo la organización de portafolios bibliográficos y la extracción de información relevante para el tema de investigación (Bolzán & Mendes Filho, 2022), como lo menciona (Afonso et al., 2012), esta metodología permite la construcción de conocimiento siguiendo un procedimiento estructurado y riguroso que minimiza la aleatoriedad y maximiza la eficiencia en la revisión bibliográfica.

La metodología parte de la definición del motor de búsqueda de artículos científicos, seguido de una serie de filtros que permiten decantar la información, para finalmente, desarrollar el portafolio bibliográfico. El primer paso, es la definición del tema de interés y un conjunto de palabras clave, que se utilizarán para el rastreo de información en los motores de búsqueda, tanto en inglés como en español; posteriormente, se ingresan las palabras en las bases de datos (palabras solas y/o combinadas) utilizando operadores booleanos. Las bases de datos utilizadas para la búsqueda de artículos son: Google Scholar, Science Direct, Scopus, Dialnet y Springerlink, la búsqueda se limita a artículos de revisión que se encuentren entre 2020 y 2025, con el objetivo de encontrar metodologías más recientes. Los artículos en bruto son exportados a un software de gestión bibliográfica (Mendeley), lo que facilita la manipulación y estandarización de la información. Se eliminan los artículos repetidos y se evalúa la representatividad con base en el contenido de las palabras clave en el título y resumen de los textos, los que no se encuentran alineados son eliminados, se verifica que los artículos se encuentren disponibles y por último se construye el portafolio bibliográfico. En la Figura 1, se resume el proceso realizado con la metodología ProKnow-C.

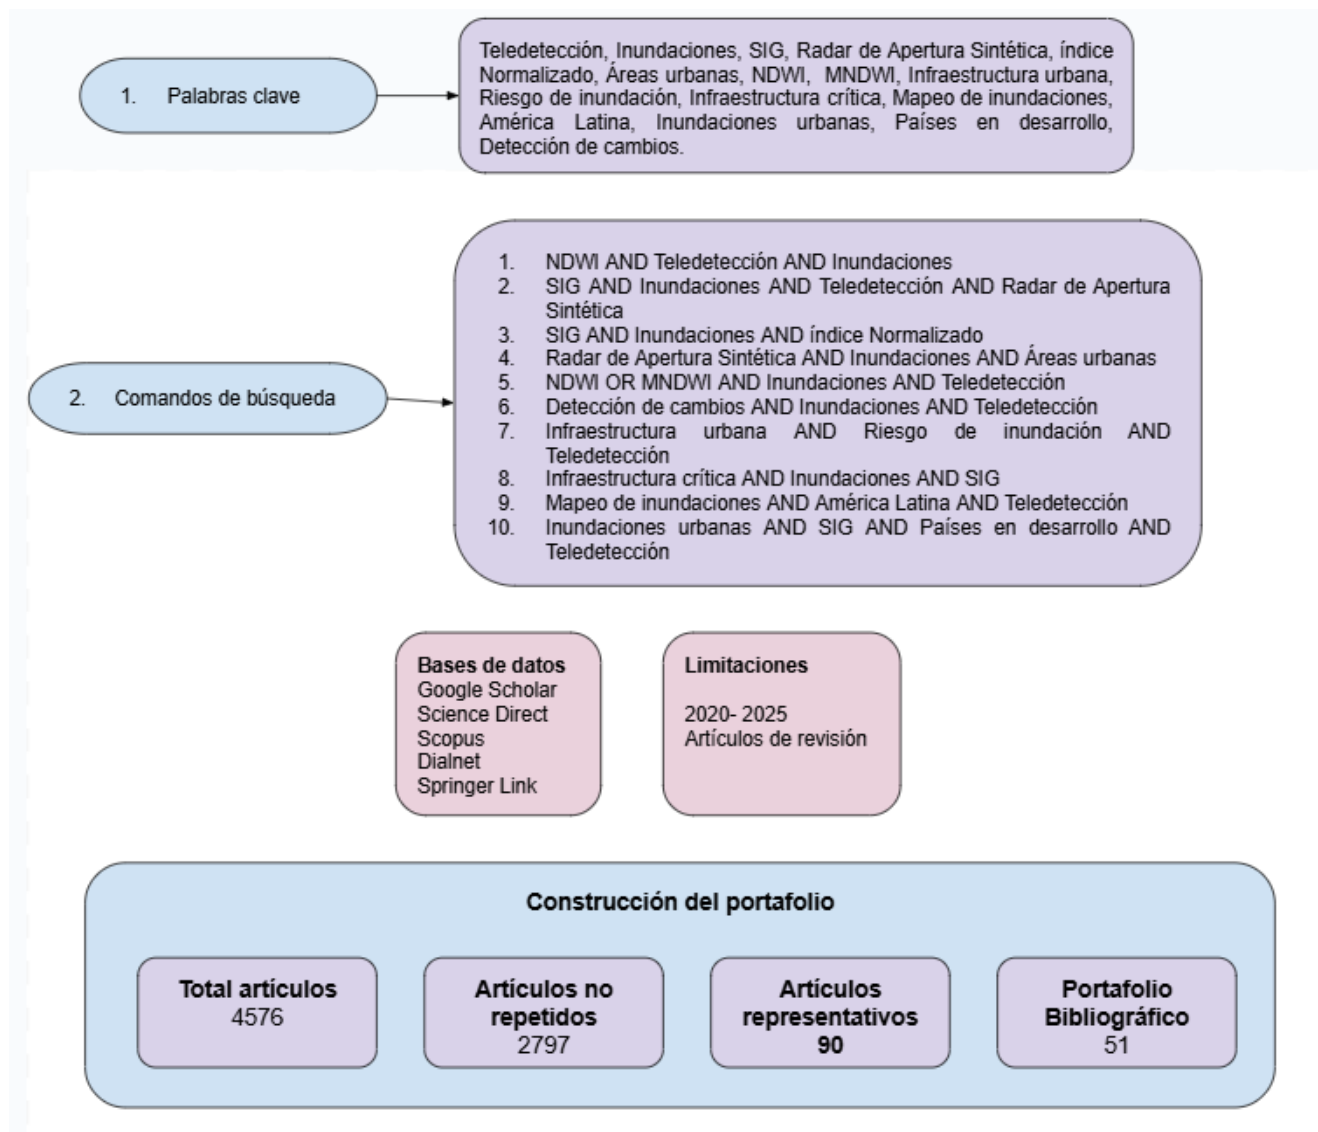


Figura 1. Proceso realizado con la metodología Proknow-C.

Resultados del proceso de revisión bibliográfica

Una vez construido el portafolio bibliográfico mediante la metodología ProKnow-C, se procede a analizar las características generales de los estudios seleccionados. Este análisis permite identificar patrones editoriales, distribución temporal, tendencias metodológicas y enfoques geográficos presentes en la literatura revisada.

Con el fin de comprender en que medios científicos se concentra la producción académica sobre inundaciones urbanas y metodologías basadas en teledetección, se presenta en la Figura 2 la distribución de referencias incluidas en la revisión bibliométrica, según la revista en que fueron

publicadas. Esta información permite visualizar las tendencias en publicaciones, la dispersión temática y el carácter multidisciplinario del área de estudio.




Figura 2. Número de publicaciones por revista.

Los resultados evidencian que, dentro de la literatura reciente sobre inundaciones urbanas, la revista *Remote Sensing* es la que reúne el mayor número de publicaciones, con un total de 14 artículos. Este predominio confirma que el estudio de inundaciones se apoya de manera significativa en la teledetección, especialmente mediante sensores satelitales ópticos y de radar SAR, que resultan fundamentales para la identificación y el mapeo de áreas afectadas.

En segundo lugar, se ubica *Water (Switzerland)*, con alrededor de 8 artículos, lo que señala la presencia de enfoques fuertemente ligados a la hidrología urbana y a la gestión del recurso hídrico.

Las demás revistas registran solo uno o dos trabajos cada una, lo que sugiere que el tema mantiene un carácter claramente multidisciplinario, involucrando campos como la hidrología, los SIG, la ingeniería, la gestión del riesgo, la teledetección y el cambio climático.

En conjunto, estos patrones muestran una fuerte concentración en revistas especializadas en teledetección y estudios del agua, lo cual coincide con las metodologías predominantes en los artículos analizados (sensores SAR, imágenes Sentinel-1 y Sentinel-2, UAV, deep learning y modelos hidrológicos). La presencia distribuida en otras revistas refleja, además, que el campo continúa ampliándose y diversificándose en cuanto a enfoques, técnicas y áreas de aplicación.

Con el propósito de identificar cómo ha evolucionado la producción científica en los últimos años, la Figura 3 presenta el número de publicaciones incluidas en la revisión bibliométrica según su año de publicación. Esta distribución permite observar la dinámica reciente del campo y reconocer posibles incrementos o fluctuaciones en el interés investigativo sobre inundaciones urbanas y metodologías basadas en teledetección.



Figura 3. Número de publicaciones por año.

Los datos muestran un crecimiento progresivo en el número de publicaciones del año 2021 al 2025, esto se puede relacionar con la intensificación global de eventos hidrometeorológicos extremos que llevaron al interés del estudio científico para comprender sus efectos urbanos. Diversos estudios identificados pueden sostener esta idea, por ejemplo, en Dera Ismail Khan se reportan para el año 2022 lluvias anómalas que superaron el 300% del promedio histórico (Sajjad et al., 2025).

De acuerdo con la bibliografía consultada, la frecuencia e impacto de las inundaciones se volverán más frecuentes y severos en el futuro debido al cambio climático, el aumento del nivel del mar y la urbanización acelerada. Esto se sustenta en Souza & de Amorim Silva, (2025) con el comportamiento de los últimos 30 años y, en Bai et al., (2021), donde mencionan que los desastres

aumentarán continuamente en futuros escenarios climáticos. Simultáneamente, la expansión de la urbanización hacia regiones vulnerables y el aumento de la impermeabilización del suelo incrementan los niveles de vulnerabilidad en muchas áreas (An et al., 2022; Da Silva et al., 2022; Souza & de Amorim Silva, 2025), lo que surge como oportunidad para realizar investigaciones aplicadas.

El aumento de publicaciones también refleja la creciente disponibilidad de datos satelitales gratuitos y de alta resolución (por ejemplo, Sentinel-1 y Sentinel-2), que han impulsado metodologías más accesibles y precisas, esto se combina con el reciente avance de la inteligencia artificial y los métodos de aprendizaje profundo que han mostrado mejoras significativas en la detección y delimitación de inundaciones , (Bai et al., 2021; Tanim et al., 2022).. Tales desarrollos permiten trabajar con volúmenes sustanciales de datos sin necesidad de un extenso trabajo de campo, una transformación metodológica que también se fortaleció después de la pandemia.

En conjunto, la evidencia indica que el aumento de publicaciones es una reacción a las demandas impuestas por fenómenos globales, climáticos, sociales y urbanos; y a la disponibilidad de nuevas tecnologías que han ampliado el rango de posibilidades para el análisis. La Figura 4 muestra la distribución geográfica de las investigaciones incluidas en la revisión, destacando únicamente los países donde se identificaron estudios centrados específicamente en inundaciones urbanas y en la cuantificación de daños sobre la infraestructura. Esta representación no pretende abarcar todos los casos analizados en la matriz, sino ilustrar los territorios en los que se han documentado experiencias empíricas directas. El resto de las referencias corresponde a estudios conceptuales, metodológicos o comparativos desarrollados en diferentes regiones del mundo, sin un vínculo territorial único.




Figura 4. Número de estudios sobre inundaciones urbanas.

En el rastreo de casos de estudio, se evidencia una gran concentración de los estudios en países asiáticos, europeos y norte americanos posiblemente debido a que se tiene mayor disponibilidad de datos satelitales, acceso a infraestructura, tecnología y recursos para investigación. Sin embargo, pocos estudios se centran en países en vía de desarrollo; por lo que se identifica como vacío u oportunidad la necesidad de más investigaciones sobre la detección y gestión adecuada de inundaciones, ya que de acuerdo con Mohamadiazar et al., (2024) la identificación y mapeo rápido de inundaciones podría reducir los daños en un 30%. La menor presencia de publicaciones o estudios, suelen coincidir con contextos en donde las capacidades institucionales son más limitadas y así mismo son los que presentan mayor vulnerabilidad frente a eventos de inundación en zonas urbanas.

En resumen, el portafolio bibliográfico construido no solo es un punto de partida sólido para comprender el estado del arte, sino también una base para las elecciones metodológicas en capítulos más recientes. Estos resultados indican que la teledetección, los sistemas de información geográfica (SIG) y los modelos de aprendizaje automático siguen siendo herramientas importantes para realizar diagnósticos de inundaciones urbanas y evaluaciones de daños en infraestructuras, al mismo tiempo que revelan grandes lagunas que deben llenarse para intensificar la investigación en contextos complejos, como los entornos urbanos. Esta revisión establece una base conceptual y metodológica para ayudar en la formulación de análisis posteriores.

Resultados

El análisis del portafolio bibliográfico permitió identificar las principales metodologías utilizadas recientemente en la detección y delimitación de inundaciones urbanas. A partir de la revisión sistemática, se agruparon los estudios según los enfoques predominantes, con el fin de comprender cómo diferentes técnicas de teledetección, SIG y modelos computacionales se aplican en distintos contextos urbanos. En esta sección se presentan los hallazgos organizados por tipo de metodología, resaltando los aportes, aplicaciones y limitaciones reportadas en la literatura.

Algunos estudios, reportan métricas de evaluación para medir precisión y confiabilidad de los algoritmos utilizados en la detección de inundaciones, los cuales se resumen en la Tabla 1.

Tabla 1. Métricas de evaluación.

Métrica	Formula	Parámetros	Descripción
Precisión global (OA)	$Exactitud = \frac{Tp + Tn}{Tp + Tn + Fp + Fn}$	Tp (verdaderos positivos): píxeles clasificados como inundados correctamente. Fp (falsos positivos): píxeles no inundados clasificados	Relación entre las muestras clasificadas correctamente y el total de muestras.
Precisión	$Precisión = \frac{Tp}{Tp + Fp}$		Mide la capacidad de clasificar correctamente las muestras inundadas.
			Relación entre las muestras inundadas

Métrica	Formula	Parámetros	Descripción
Sensibilidad o Recall	$Recall = \frac{Tp}{Tp + Fn}$	erróneamente como inundados.	correctamente y todas las muestras inundadas.
IoU	$IoU = \frac{Tp}{Tp + Fp + Fn}$	Tn (verdaderos negativos): pixeles no inundados correctamente clasificados. Fn (falsos negativos): pixeles inundados no detectados.	Intersección sobre la unión: mide el solapamiento entre la predicción del área inundada y la referencia.
F1	$F1 = 2 \frac{Precisión \times Recall}{Precisión + Recall}$		Combina las medidas de precisión y sensibilidad.

Fuente: Adaptado de (Amitrano et al., 2024)

Herramientas de inteligencia artificial

Machine Learning

El aprendizaje automático (Machine Learning, ML) se ha consolidado como una de las tendencias metodológicas más relevantes en la detección, delimitación y análisis de inundaciones, especialmente en entornos urbanos donde la diversidad de elementos del paisaje dificulta la aplicación de métodos tradicionales. A diferencia de las técnicas basadas en umbrales fijos o reglas manuales, los modelos de ML aprenden a partir de ejemplos etiquetados, es decir, a partir de imágenes donde previamente se ha indicado qué áreas están inundadas y cuáles no. Este enfoque se basa en la identificación de patrones complejos asociados a la presencia de agua, incluso cuando su apariencia presenta variaciones importantes debido a sombras, estructuras urbanas, vegetación o ruido característico de sensores SAR entre otras.

En el Himalaya, la integración de sensores ópticos, SAR, fotografías aéreas y LiDAR permitió crear modelos digitales de elevación de alta precisión para analizar la dinámica del flujo de inundación. Métodos de aprendizaje automático como redes neuronales y Random Forest mejoran la predicción de daños y la identificación de zonas vulnerables. El uso de LiDAR alcanzó precisiones del 95 %, en contraste con el 70 % registrado por levantamientos topográficos tradicionales (Roohi, Dehghani, et al., 2025).

En San Diego, California se utilizaron métodos supervisados y no supervisados para la detección de áreas inundadas para los años 2017 y 2018, los modelos supervisados fueron entrenados con un conjunto de imágenes de Sentinel-1 y diversos datos como reportes de cierre de carreteras por eventos de inundación e información de campo. El modelo Random Forest muestra imprecisiones en la identificación de zonas inundadas en zonas urbanas. Por otra parte, los métodos no supervisados, como la detección de cambios, requieren menos datos de entrenamiento y generan información con mayor rapidez. Los métodos de Support Vector Machine (SVM) y Change detection, obtuvieron mejores resultados, alcanzando una precisión de 0.85 y 0.81 respectivamente

y ambos una exactitud de 0.87; sin embargo, el más efectivo es Change Detection ya que no requiere datos de entrenamiento y requiere menor tiempo para el cálculo (Tanim et al., 2022).

Machine Learning, permite la integración de múltiples fuentes, como imágenes de sensores ópticos, imágenes de radar, DEM, capas de infraestructura urbana e información hidrológica. Esta flexibilidad es de gran utilidad en la detección de inundaciones en entornos urbanos donde por su complejidad son altamente variables. Autores como (Baghermanesh et al., 2022) destacan que la integración de atributos derivados de SIG con señales SAR mejora de manera significativa la capacidad de los modelos para distinguir entre agua real y falsos positivos generados por superficies reflectivas.

Otros casos, como el de Australia (Roohi, Ghafouri, et al., 2025), aprovechan la precisión de imágenes PlanetScope y modelos como Decision Tree, Naive Bayes o KNN para generar mapas detallados del avance del agua. En zonas urbanas densas (Baghermanesh et al., 2022), el Random Forest se refuerza con simulaciones SAR y variables como uso del suelo o distancia a los ríos, lo que mejora la detección de inundaciones.

Deep Learning

El Deep Learning en los últimos años de acuerdo con los estudios revisados se ha convertido en una de las herramientas más usadas para identificar y analizar inundaciones en zonas urbanas, entre sus ventajas principales está que permite reconocer o entender patrones difíciles desde las imágenes, por ejemplo, pavimentos, y techos, que usualmente tienden a confundir a los métodos tradicionales. A diferencia de los modelos supervisados de machine learning, métodos como U-Net, ResUNet, FCN, BASNet o Deeplab v3, tienen la capacidad de delimitar áreas inundadas con alto nivel de detalle, ya que realizan la clasificación píxel a píxel y no requieren reglas predefinidas para diferenciar las clases.

En Bolivia, se empleó el conjunto de datos Sen1Floods11 (Bonafilia et al., 2020), el cual está diseñado para entrenar modelos de Deep Learning con imágenes Sentinel-1 y Sentinel-2, orientado a la detección automática de zonas inundadas. Se evaluaron diversos métodos como Otsu, FCN-ResNet50, Deeplab v3 y U²Net, aunque BASNet fue el que obtuvo el mejor desempeño al identificar tanto agua permanente como temporal. Su arquitectura encoder-decoder, junto con un módulo de refinamiento residual, permitió mejorar los bordes y distinguir cambios sutiles sin necesidad de información previa o análisis multitemporales complejos (Bai et al., 2021).

En Miami-Dade, Florida, se combinaron imágenes Sentinel-1A (polarización VV) con variables locales como pendiente, tipos de suelo hidrológico, precipitación e impermeabilización para entrenar el modelo U-Net. Este generó mapas binarios de inundación con exactitudes entre 91,57% y 93,73 %, demostrando que la información local mejora significativamente la reducción de falsos positivos (Mohamadiazar et al., 2024).

En Eslovenia, el estudio se centró en tres áreas afectadas por inundaciones, utilizando Sentinel-1, Sentinel-2 y el modelo ResUNet entrenado con Sen1Floods11. Las métricas obtenidas (IoU 60 %, F1-Score 65 %, precisión 65 % y Recall 65 %) se consideran aceptables, aunque se evidenciaron

limitaciones relacionadas con la resolución del SAR en zonas urbanas densas y la baja presencia de eventos europeos en los datos de entrenamiento, lo que genera la necesidad de ajustes locales posteriores (Belenguer-Plomer et al., 2025). El mapeo de inundaciones en entornos urbanos presenta limitaciones debido a la falta de datos etiquetados para entrenamiento de modelos y la complejidad de las señales de retrodispersión de los radares SAR en estas zonas. Para abordar este desafío, en Iwaki, Japón y Houston, Estados Unidos, se implementó el módulo Urban-aware U-Net, para mejorar la precisión en la detección de inundaciones (Zhao et al., 2022).

Los casos de estudio presentados muestran que el Deep Learning no se aplica de la misma manera en todos los casos, sino que se ajusta según las condiciones del territorio, la disponibilidad de datos y la complejidad del evento. En áreas urbanas muy densas, por ejemplo, modelos como U-Net y ResUNet suelen funcionar mejor porque logran diferenciar las zonas inundadas incluso cuando se presentan limitaciones como el efecto de doble rebote o superficies muy reflectivas, que son problemas comunes en imágenes SAR tomadas sobre ciudades (Belenguer-Plomer et al., 2025)

En conclusión, la evidencia revisada apunta a que los métodos de aprendizaje profundo representan un avance significativo en el estudio de inundaciones urbanas. Su capacidad para integrar múltiples fuentes de datos, reconocer patrones complejos y adaptarse a diferentes condiciones territoriales los convierte en herramientas esenciales dentro de las metodologías contemporáneas de análisis de riesgo.

Métodos basados en estadística y segmentación

Los métodos estadísticos y de segmentación se utilizan en el análisis de imágenes, especialmente en teledetección. El método de Otsu genera mapas binarios que clasifica los píxeles en agua/no agua mediante histogramas de intensidad, el umbral óptimo es aquel que maximiza la varianza; es decir, logra la mejor separación estadística entre las clases. Los métodos como Otsu, Fuzzificación e Iso-clustering, son herramientas útiles para la detección de inundaciones, principalmente para estudios donde no se cuenta con gran volumen de información; sin embargo, cuenta con limitaciones de detalle y ruido. En Bolivia, como método comparativo se emplea el umbral de Otsu. Para la detección de inundaciones, se obtuvo una precisión global alta (93.64%); sin embargo, obtuvo valores de mIoU e IoU más bajos que los métodos basados en aprendizaje profundo evaluados, por lo que presentan mayores desafíos en la detección de inundaciones (Bai et al., 2021).

En 2022, la ciudad de Dera Ismail, Pakistán, sufrió severas inundaciones, afectando zonas rurales y urbanas, estos eventos fueron causados por lluvias intensas, afectando la dinámica de inundaciones locales. Se utilizó el método de máxima verosimilitud, para clasificar el uso del suelo y detectar cambios en las áreas afectadas por inundaciones, asignando a cada píxel de la imagen a la clase que tiene la mayor probabilidad de pertenecer, basándose en las estadísticas de las clases previamente definidas. Se utiliza superposición basado en SIG antes y después de los eventos de inundación. Se complementa con el cálculo del MNDWI y se validan los mapas con datos obtenidos de Google Earth Pro. La aplicación del MNDWI junto con la clasificación supervisada basada en el algoritmo de máxima verosimilitud permite una mejor precisión en la delimitación de áreas inundadas en la zona urbana, con una precisión global cercana al 90% (Sajjad et al., 2025).

En Lagos, Nigeria, se evaluaron cuatro décadas (1990, 2000, 2010 y 2020) de imágenes Landsat mediante clasificación supervisada de máxima verosimilitud. Se generaron matrices de confusión para cada periodo, con valores Kappa entre 0,76 y 0,93, lo que indica alta precisión. Los resultados muestran que las zonas más afectadas generalmente coinciden con áreas de reciente urbanización donde la infraestructura de drenaje es insuficiente, incrementando la exposición a inundaciones. El estudio genera mapas temáticos que muestran que las zonas con mayor incidencia de inundaciones coinciden con áreas de crecimiento urbano reciente, que en algunos casos no cuentan con estructuras adecuadas de drenaje lo que incrementa la tendencia de inundaciones (Koko et al., 2021).

Método probabilístico/ Enfoque Bayesiano

Los métodos probabilísticos y bayesianos se han ido empleando en el análisis de inundaciones urbanas, para resolver incertidumbres asociadas a la retrodispersión SAR y la compleja respuesta electromagnética de áreas urbanas, puesto que permiten clasificar los píxeles de manera rígida; estos modelos calculan la probabilidad de que un píxel esté realmente inundado a partir de la información que aportan los sensores SAR, los métodos probabilísticos, resultan ser útiles en los casos en que los escenarios del contraste de “inundado” o “no inundado” no es tan claro de determinar, por ejemplos zonas de vegetación mixta, sombras por estructuras, entre otras.

En (Zhu et al., 2025), se prueba un análisis de inundaciones en países como Japón, Bangladesh, Estados Unidos y China, donde utiliza una combinación de diversas técnicas de teledetección, modelos hidrológicos y análisis estadísticos, lo que permite superar desafíos en la detección de áreas con complejidad espacial y electromagnética. En Japón para un evento de inundación de 2018, se usaron datos de ALOS-2 (banda L) y se validan los resultados con mapas provistos por la Geospatial Information Authority of Japan (GSI), en Bangladesh para un evento de inundación de 2024 se usaron datos de Sentinel-1 (banda C) y validación con imágenes de Sentinel-2, en Estados Unidos para inundaciones en 2017, se utilizó el satélite TerraSAR-X (banda X) con validaciones a partir de imágenes aéreas de alta resolución de la NOAA, la banda X, mostró ser efectiva en la detección en áreas urbanas densas, ya que brinda una resolución espacial fina para detectar áreas inundadas con detalle, en China se monitorean secuencias de inundación a largo plazo y se valida con datos de descarga media diaria de estaciones hidrológicas locales. Estos datos se integran con un método probabilístico basado en el enfoque de inferencia bayesiana, que estima la probabilidad de que un píxel está inundado utilizando su coeficiente de retrodispersión obtenido de imágenes SAR.

Posterior al mapa de probabilidad de inundación, se aplica el umbral de probabilidad, con un valor de 0,7; es decir, los píxeles con una probabilidad de inundación mayor o igual a 0,7 se clasifican como inundados, los que tienen un menor valor se consideran no inundados, de este proceso se obtiene un mapa binario. Finalmente, se vectoriza el resultado y se eliminan las regiones de ruido, donde se encuentran parches aislados. Este enfoque que integra múltiples datos resulta efectivo en entornos complejos, abordando desafíos como la reflexión doble y la heterogeneidad del terreno evitando sobreestimaciones, facilitando la gestión efectiva de inundaciones y la toma de decisiones basada en datos. En comparación con métodos tradicionales y de aprendizaje profundo, el método propuesto obtiene resultados positivos en las métricas de evaluación, donde la precisión varía de 0,762 a 0,945, destacando su capacidad de minimizar falsos positivos, especialmente en áreas con

vegetación y zonas urbanas y la exactitud general varía entre 0,865 y 0,921, superando técnicas tradicionales no supervisadas y modelos basados en machine learning como el umbral de Otsu, U-Net y PCA-k-means (Zhu et al., 2025).

Métodos de Ensamblaje

Los modelos Ensemble o modelos de ensamblaje, son combinaciones de técnicas individuales de machine learning, con el objetivo de mejorar la precisión y la eficiencia de tareas de predicción y clasificación. El objetivo es minimizar errores y mejorar la capacidad de generalización (Roohi, Ghafouri, et al., 2025).

Estos modelos ofrecen soluciones para la detección efectiva de inundaciones. En la provincia de Thua Thien Hue, Vietnam se realiza un estudio que integra SIG, teledetección y modelos híbridos para la gestión de inundaciones. La preparación de los datos para el modelo se generan a partir de imágenes Sentinel-1A pre y pos-inundación, estas imágenes se procesan para crear un mapa binario que representa zonas inundadas y no inundadas, además se seleccionan 14 factores que pueden influir en las inundaciones, como la pendiente, distancia a ríos, vegetación, lluvia, entre otros; el procesamiento de esta información permite obtener un total de 1.621 puntos de muestra, se aplica el algoritmo Random Forest (RF) para determinar la importancia de cada factor, eliminando variables redundantes. Los datos se dividen de la siguiente forma: 60% para entrenamiento, 20% para validación y 20% para probar los modelos. Se aplican modelos de machine learning como SVM, RF, BA (Bagging) y MLP y se optimizan mediante el algoritmo Bald Eagle Search (BES), que mejora el ajuste de parámetros y capacidad predictiva. Este método permite tener mapas discretizados en cinco niveles de susceptibilidad de inundación (muy bajo- muy alto), lo que apoya la gestión de riesgo y los procesos de ordenamiento y planificación (Ha et al., 2022).

Asimismo, (Sathees Babu et al., 2025), aplica un modelo híbrido de Deep Learning llamado ICENet, que integra componentes de características espaciales y temporales para predecir inundaciones y los niveles del agua en entornos urbanos complejos y que cuentan con pocos datos en tiempo real. Este método proporciona una herramienta útil para la gestión de emergencias y la planificación urbana, por su respuesta rápida y menor requerimiento de tiempo para el entrenamiento.

Índices espectrales

Los índices espectrales son operaciones que combinan bandas de imágenes satelitales con el objetivo de resaltar características específicas de la superficie terrestre, como vegetación, agua, suelo o nieve. En la detección de inundaciones los índices más utilizados corresponden con el Índice de Agua Normalizado (NDWI) y el Índice de Agua Modificado Normalizado (NMDWI). Este último, es más preciso para la delimitación de inundaciones, además minimiza el ruido de las áreas construidas (Sajjad et al., 2025).

La delimitación de inundaciones en el sur de New Orleans, Luisiana para el huracán Ida en 2021 y en Houston, Texas para el huracán Harvey en 2017, se utiliza el análisis de imágenes multitemporales de sensores ópticos y radar. La detección mediante imágenes SAR, se realiza considerando que las superficies de agua reflejan una señal reducida, también se utilizan imágenes

ópticas de Landsat-8 y Sentinel 2 para validar y ajustar los parámetros de umbralización. Se generan mapas que representan la extensión de las inundaciones para ambos eventos. Para las imágenes SAR, se calculan los índices NDFI, RI y DII, para detectar inundaciones basadas en el cambio de retrodispersión entre imágenes pre y post inundación y se comparan con índices de imágenes ópticas como NDVI, NDWI, NDPI y el MNDWI, que es un índice modificado que mejora la detección de cuerpos de agua. El porcentaje de similitud entre los índices SAR y ópticos, varía entre el 77% y 80% para los tres índices SAR principales. En ambos eventos, la nubosidad representa limitaciones para el uso de las imágenes ópticas como única fuente de información, para el huracán Ida representa el 13% y para el Harvey el 40% de nubosidad; sin embargo, dado que SAR opera bajo condiciones meteorológicas y luminosas adversas, esta metodología permite detectar inundaciones en zonas cubiertas por nubes donde las imágenes ópticas presentan limitaciones. Este procesamiento se realiza en la plataforma Google Earth Engine, lo que facilita la automatización, escalabilidad y reproducibilidad del método (Hamidi et al., 2023).

Internet of Things (IoT), sensores

El uso de sensores inalámbricos es una opción para el seguimiento en tiempo real de las inundaciones en zonas urbanas, principalmente donde las redes de drenaje o el entorno construido son un obstáculo para el monitoreo con métodos tradicionales. Su diferencia con métodos basados solo en imágenes satelitales es que los sensores inalámbricos permiten medir variables críticas como lo son el caudal, el nivel de agua, la presión del agua, y transmitirla de forma inmediata, y así mismo permite ser medido en eventos de lluvias intensas. Por su capacidad de operar de forma continua, son una buena alternativa para sistemas de alerta temprana que apoye la toma de decisiones para mejorar la capacidad de respuesta frente a emergencias.

En la ciudad de São Carlos, Brasil, para la predicción y detección en tiempo real de inundaciones se utilizan Sensores inalámbricos (Wireless Sensor Networks-WSN), asociado con el concepto de internet de las cosas (IoT), lo que permite respuestas rápidas ante la ocurrencia de fenómenos extremos. Se demostró la eficacia de este método en la predicción de inundaciones a corto plazo en entornos urbanos; sin embargo, las necesidades de mantenimiento y el alto costo son algunos de los retos que limitan su escalabilidad. Se destaca que los modelos estadísticos son adecuados para modelización a largo plazo, utilizando tendencias y estimación de eventos extremos basados en patrones climáticos y series temporales históricas lo que puede contribuir con la planificación de las ciudades; mientras que los modelos que utilizan machine learning y relacionan las condiciones climáticas destacan por la eficiencia en la predicción de eventos de inundación a corto plazo, fundamental para la gestión de emergencias. En conclusión, los modelos híbridos obtienen predicciones más precisas (Jackowski et al., 2015).

Para la detección de inundaciones en zonas urbanas de Mumbai, India, se aplica una metodología que combina IoT, datos meteorológicos y redes neuronales artificiales (ANN), por su capacidad para manejar datos ambiguos y discretos. El modelo tiene como entrada datos meteorológicos históricos y en tiempo real y datos recopilados por dispositivos IoT instalados en sistemas de drenaje, que toman información sobre el flujo, obstrucciones y condiciones del drenaje. La clasificación del modelo genera mapas con simbología que representa la presencia de dispositivos IoT y la severidad de las inundaciones, lo que permite la identificación rápida de zonas afectadas (Goyal et al., 2021).

En conjunto, los estudios muestran que los sensores inalámbricos y las tecnologías IoT representan una estrategia eficaz para el monitoreo continuo, particularmente en zonas urbanas con infraestructura compleja. Aunque presentan limitaciones asociadas a costos y mantenimiento, su capacidad para entregar información inmediata los convierte en herramientas esenciales dentro de los sistemas de alerta temprana.

Drones, UAVs, LiDAR

Los vehículos aéreos no tripulados (UAV), son una herramienta usada para identificar y mapear las inundaciones urbanas, con sensores que integran cámaras RGB o sensores multiespectrales que permiten capturar datos detallados con alta resolución espacial, puesto que se logran distinguir objetos muy pequeños, e identificar techos, vehículos, bordes de río, charcos, entre otros. Además, los UAV presentan flexibilidad para la obtención de los datos ya que los vuelos se programan a demanda, permitiendo obtener insumos de forma rápida. Estos se integran con redes neuronales profundas, particularmente Redes Neuronales Convolucionales (CNN), para segmentar y clasificar áreas inundadas. Estas técnicas tienen el potencial de realizar análisis multitemporal para la predicción de eventos; además, la integración con DEM mejora la evaluación de riesgos de inundación (Osco et al., 2021).

En los Andes sudamericanos, se estudia la delimitación y gestión de inundaciones mediante el uso de Vehículos Aéreos No Tripulados (UAVs) equipados con sensores LiDAR, estos datos se procesan para obtener DEMs detallados para identificar alteraciones geomorfológicas en el terreno a causa de eventos de inundación y evaluar zonas vulnerables, propensas a la ocurrencia de desastres como movimientos en masa, que se presentan en este contexto montañoso y la identificación de daños ocurridos. Los LiDAR tienen alta resolución espacial, por lo que la información es precisa incluso bajo cubierta vegetal densa, es un método rápido que recolecta información en regiones de difícil acceso o peligrosas tras la ocurrencia de desastres y apoya la toma eficaz de decisiones y priorización de acciones; por otra parte, presenta limitaciones como la dependencia de condiciones meteorológicas para recolectar información y cobertura limitada, ya que tiene limitaciones de autonomía y alcance (Roohi, Dehghani, et al., 2025).

En el centro de Italia, en las cuencas de los ríos Metauro y Cesano, la delimitación de inundaciones y el estimado de infraestructura afectada, se determina con el uso de LiDAR aerotransportado, cubriendo áreas fluviales, llanuras aluviales y zonas urbanas propensas a inundaciones. Los LiDAR capturan datos en forma de nube de puntos en 3D con alta densidad. Para el procesamiento de datos se aplican algoritmos de clasificación, lo que permite diferenciar los objetos artificiales de las demás coberturas, los DSM y DTM se generan con resoluciones de 1 metro y se complementa con datos del Sistema Global de Navegación por satélite (GNSS) para validar las elevaciones y posición topográfica. La detección de zonas inundadas se realiza mediante técnicas de análisis espacial. Esta metodología juega un papel importante en la gestión del riesgo y la planificación urbana, la integración con modelos hidrodinámicos permite estimar niveles de agua y su impacto en construcciones o el cruce de estos modelos con datos de infraestructura en un entorno SIG que permitan identificar afectaciones. Los LiDAR también se pueden integrar con UAVs, los cuales realizan vuelos de bajo nivel que obtienen información con alta resolución espacial (Malinverni et al., 2025).

En Hunnicutt Creek, Carolina del Sur, se implementa una metodología para evaluar los riesgos de inundación en arroyos urbanos, combinando técnicas de aprendizaje automático, LiDAR terrestre y modelado 3D. Se utiliza el algoritmo Prophet para detectar cambios en los niveles del agua basado en datos históricos de sensores de nivel, estaciones meteorológicas y de calidad del agua, que pueden aportar información adicional que mejora los modelos de predicción, ya que reflejan dinámicas hidrológicas y ambientales relacionadas con tormentas y cambios de flujo en el arroyo, lo que permite identificar zonas propensas a inundaciones y proporciona información sobre cómo los cambios en el nivel se relaciona con los volúmenes de agua en el canal del arroyo. Se utiliza un sensor LiDAR de 32 canales llamado Surveyor montado en mochila para mapear con precisión el canal del arroyo y sus alrededores, el cual genera DEM con resoluciones entre 3 y 18 cm, este modelo permite visualizar cómo los cambios en el nivel del agua se traducen en inundaciones. La combinación de los pronósticos de nivel de agua y el modelado 3D, permite identificar zonas con alto riesgo de erosión, sedimentación y daños estructurales y conocer posibles eventos de inundación con suficiente tiempo de antelación para la gestión de riesgos. Esta metodología obtuvo un coeficiente de determinación $R^2 > 0,9$, lo que indica alta precisión en la predicción de cambios en los niveles de agua (Bolick et al., 2023).

La identificación y detección de zonas inundadas en el contexto urbano, es importante para el despliegue de acciones y atención a la ocurrencia de desastres, los UAVs, son instrumentos empleados en la captura de imágenes de alta resolución en tiempo real, aportando datos precisos de la extensión afectada y el impacto sobre infraestructura urbana. Se utilizan técnicas de aprendizaje profundo, principalmente redes neuronales convolucionales (CNN) para clasificar las áreas afectadas e identificar signos de daño en infraestructuras. Esta información se integra con SIG, generando mapas detallados de inundaciones e identificación de zonas con afectaciones (Akinsoji et al., 2024).

Imágenes satelitales con otros instrumentos

La revisión de los estudios muestra que la combinación de imágenes ópticas y radar (SAR), integradas dentro de entornos SIG, es un método empleado con frecuencia para mejorar la detección y delimitación de las inundaciones. En los casos analizados, las imágenes ópticas suelen aportar información útil cuando hay buena iluminación y baja nubosidad, mientras que los datos SAR complementan el análisis en situaciones donde las condiciones atmosféricas limitan el uso de sensores ópticos. Varios trabajos utilizan técnicas SIG y capas temáticas para refinar esta integración, lo que ayuda a reducir errores comunes como la confusión causada por sombras, suelos húmedos o superficies altamente reflectivas. En conjunto, los artículos coinciden en que la fusión de diferentes fuentes de datos mejora la precisión y consistencia de los mapas de inundación, especialmente en zonas urbanas con mayor complejidad espacial.

Una de las estrategias más eficaces para mejorar la detección de inundaciones, podría ser la combinación de imágenes ópticas y radar (SAR), complementada con variables derivadas del SIG, en especial para escenarios urbanos donde un solo tipo de sensor suele presentar limitaciones; Mientras las imágenes ópticas permiten identificar agua con claridad bajo condiciones favorables de luz y baja nubosidad, el radar es capaz de penetrar nubes y captar la textura y el comportamiento de la superficie del agua incluso durante tormentas o en situaciones meteorológicas adversas,

entonces esta integración de fuentes reduce errores comunes como falsos positivos por sombras, suelos húmedos o superficies altamente reflectivas y mejora su precisión.

En eventos de inundación reportados en 2015 en Nepal, se utilizan imágenes satelitales de sensores ópticos de Sentinel-2 y Landsat, con las que se identifican cambios en la superficie terrestre antes y después de los eventos de inundación. Se utilizó el NDWI para delimitar las zonas afectadas y se integraron con datos de Modelos Digitales de Elevación (DEM) y datos topográficos lo que mejora la comprensión del comportamiento hidrológico y geomorfológico. Los resultados se validan con datos de campo, reportes de autoridades locales y procesos de participación comunitaria, para validar y calibrar los mapas generados. Finalmente, los mapas resultantes se sobreponen con datos de infraestructura y zonas cultivadas para la cuantificación e identificación de zonas que presentan afectaciones, lo que apoya la toma de decisiones ante emergencia y los procesos de reconstrucción. Se presentan limitaciones como la resolución espacial que puede ser insuficiente para evaluaciones localizadas, la presencia de vegetación y sombras puede inducir errores en la clasificación de zonas inundadas, condiciones atmosféricas y el procesamiento de esta información requieren conocimientos especializados y software adecuados (Roohi, Dehghani, et al., 2025).

Otro grupo de trabajos combina la teledetección con variables hidrológicas y geomorfológicas, lo que permite entender mejor el comportamiento del agua; un ejemplo de esto se evidencia en estudio realizado por Mohamadiazar et al., (2024) en La Florida donde las imágenes Sentinel-1 se integran con datos de pendiente, impermeabilización, tipo de suelo hidrológico y precipitación diaria para alimentar un modelo U-Net que predice la extensión de la inundación con exactitud. Lo que demuestra esta combinación es que la integración de sensores SAR con variables físicas del territorio reduce falsos positivos y permite mapas más coherentes con la realidad.

En un nivel más avanzado, algunos estudios incorporan modelos hidrológicos operativos, como el caso de Japón, Bangladesh, EE. UU. y China (Zhu et al., 2025), donde imágenes SAR multibanda (L, C y X) se integran con el modelo hidrológico Today's Earth (TE) dentro de un marco probabilístico. Este enfoque permite estimar inundaciones incluso en lugares con escasa disponibilidad de datos, y mejora notablemente la consistencia entre la información satelital y la dinámica real del agua en ríos y zonas urbanizadas.

Finalmente, varios artículos proponen la integración de información basados en análisis multicriterio, SIG y datos de teledetección, como ocurre en Egipto (Zhran et al., 2024), India (Alex Immanuel Jeyasingh et al., 2024) y Vietnam (An et al., 2022). Estos estudios no solo consideran factores físicos como pendiente, elevación o distancia a ríos, sino también variables sociales y demográficas que ayudan a entender mejor la vulnerabilidad urbana.

Síntesis metodológica

Para ofrecer una visión general del conjunto de metodologías aplicadas en los estudios revisados, se incluye la Tabla 2, donde se agrupan las técnicas según su naturaleza y aplicación. Esta síntesis permite apreciar cómo convergen diferentes enfoques desde el aprendizaje profundo hasta los métodos probabilísticos y multisensoriales en la identificación, clasificación y análisis de inundaciones en zonas urbanas.

Tabla 2. Metodologías que utilizan sensores remotos integrado a SIG para la detección de inundaciones en zonas urbanas.

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
Deep Learning	(Bai et al., 2021)	Bolivia	Teledetección, BASNet, FCN-ResNet50, Deeplab v3, U ² Net	Sentinel-1, Sentinel-2, conjunto de datos Sen1Floods11	Mejor modelo BASNet. Métricas agua temporal mIoU:47.88%, IoU:76.74%, OA: 95.59%	- Mejor rendimiento en escenarios complejos. - Automatización y escalabilidad.	- Altos recursos computacionales. - Requiere datos etiquetados de alta calidad.	10 metros
	(Mohamadzadeh et al., 2024)	Florida, EE. UU.	Teledetección, U-Net	SAR Sentinel 1 (polarización VV) + Datos de influencia espacial y precipitación	Métricas de prueba. Precisión: 94.07%, Recall: 86%, F1 Score: 89.85%, Overall Accuracy: 93.73%	- Integración de múltiples fuentes de datos. - Alta precisión y capacidad de segmentación detallada a nivel de píxel.	- Limitación en la resolución temporal de las imágenes satelitales y su integración con datos de precipitación diaria.	10 metros
	(Zhao et al., 2022)	Houston (EE. UU.), Iwaki & Koriyama (Japón), Beledweyne (Somalia), Beira (Mozambique)	Urban-Aware U-Net; DL; atención por canales; normalización condicionada; fusión intensidad + coherencia	Sentinel-1 SLC VV/VH; intensidad pre/post-evento; coherencia pre/evento; máscaras urbanas probabilísticas; referencias ópticas y SAR	F1 FO: 0.82–0.87; F1 FU: 0.51–0.66; Kappa: 0.51–0.83	- Mejora detección de inundación urbana - Reduce falsos positivos - Generalizable entre países	- Errores en zonas con vegetación densa - Confusión por suelos secos/rocosos - Depende de calidad de la máscara urbana	Sentinel-1: 20 m Imágenes ópticas: 35 cm Skysat: 0.5 m
	(Belenger-Plomer et al., 2025)	Eslovenia	Teledetección, ResUNet	Sentinel-1, Sen1Floods11, validación mapas manuales de Copernicus EMSR.	Métricas promedio (tres áreas de estudio). IoU: 60%, F1 Score: 0.65%, Precisión: 0.65, Recall: 0.65	- Capacidad de captar características complejas.	- Limitaciones para detección de inundaciones pequeñas o terrenos complejos, como	10 metros

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
							las zonas urbanas.	
métodos basados en estadística y segmentación	(Sajjad et al., 2025)	Pakistán	Teledetección, SIG, Google Earth Pro, MLC, matrices de confusión.	Landsat-9 (MNDWI), Puntos de referencia y validación.	OA: 89%- 93% UA: 86%- 93% PA: aproximadamente 89.37%	- Modelo escalable. - Landsat 9 ofrece mejoras en la calidad de los datos.	- Limitaciones con resolución espacial y temporal. - Errores de clasificación en entornos urbanos.	30 metros
	(Koko et al., 2021)	Lagos, Nigeria	Teledetección (análisis multitemporal), Clasificación supervisada MLC, Matrices de confusión, SIG	Imágenes satelitales multitemporales, Landsat (1990–2020), datos sociodemográficos y espaciales.	OA: 85%- 95%, Coeficiente Kappa: 0.76- 0.93	- Análisis multitemporal que permite identificar áreas vulnerables con el crecimiento urbano. - Asignación precisa de los píxeles a las categorías de cobertura del suelo.	- Limitaciones en la detección de cambios rápidos o pequeños. - Dependencia de la calidad de las imágenes satelitales (afectadas por condiciones atmosféricas, sobras, nubes)	30 metros
	(Bai et al., 2021)	Bolivia	Teledetección, Umbral de Otsu	SAR Sentinel-1 (banda VH)	Métricas agua temporal mIoU:42.23%, IoU:69.28%, OA: 93.64%	- Simplicidad y rapidez. - No requiere entrenamiento.	- Poco precisos en escenarios complejos.	10 metros
Machine Learning	(Roohi, Dehghani, et al., 2025)	Región del Himalaya	Teledetección, UAVs con LiDAR, ML (RF, ANN), Modelación hidrológica,	Landsat, Sentinel-1, Sentinel-2, fotografías aéreas, GIS, DEM	x	- Alta precisión en la identificación de zonas afectadas. - Análisis rápidos que reducen el tiempo de respuesta.	- Limitaciones climáticas o meteorológicas. - Resolución temporal y	Sentinel 1 y 2: 10 m Landsat: 30m UAVs LiDAR: alta

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
			Participación comunitaria				espacial de los datos satelitales.	
	(Tanim et al., 2022)	San Diego-California	Teledetección, Machine learning (SVM, RF, MLC, CD- no supervisado)	Sentinel-1 (SAR), Puntos de validación, datos espaciales urbanos (lluvia, nivel, cierres viales)	SVM y Detección de cambios, fueron los modelos más efectivos. RF obtuvo el menor rendimiento.	- Toma datos independientemente de las condiciones climáticas. - Change Detection (CD), resulto ser efectivo en la detección temprana de inundaciones.	- Resolución limitada de las imágenes SAR. - Limitaciones en la detección de inundaciones menores. - Los métodos no supervisados requieren datos de validación.	10 metros
	(Bagher manesh et al., 2022)1	Canadá	PolnSAR + Random Forest (clasificación mejorada en zonas urbanas con múltiples rebotes)	TerraSAR-X, simulaciones SAR, DEM, variables auxiliares (distancia a ríos, uso del suelo, pendiente)	PolnSAR+ SAR simulado+ características auxiliares. Precisión general: 93.1% en áreas urbanas.	- Mejora la precisión de la detección de inundaciones. - Buen desempeño en zonas complejas (urbanas). - Independencia de condiciones atmosféricas.	- Complejidad del modelo y mayor requerimiento de datos. - Dependiente de datos auxiliares. - Sensibilidad a condiciones específicas. - Requiere validación en distintos lugares para evaluar robustez y generalización.	TerraSAR-X: 3 metros. DTM (LiDAR): 1 metro.

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Gokon et al., 2023)	Mabi-town, Kurashiki (Japón), inundaciones 2018	Análisis multiescala SAR, segmentación multi-resolución (region-growing), machine learning (Decision Tree, LR, AdaBoost)	ALOS-2/PALSAR-2 (pre y post-evento), coeficiente de correlación, diferencia de retrodispersión, desviación estándar local, mapas GSI de inundación	Modelos con mejor rendimiento AdaBoost análisis combinado, pequeña y gran escala, siendo el modelo AdaBoost el que tiene mayor precisión y F1 Score.	- Alta precisión en áreas urbanas - Integración multiescala mejora F1 en +8–9%	- Sensible al tamaño del kernel - No evalúa transferencia a otras ciudades - Depende del ángulo y geometría SAR	ALOS-2/PALSAR-2: 3 m
	(Narin et al., 2025)	Países Bajos (Zutphen y Heijen, inundaciones julio 2021)	Fusión multisensor (SAR + óptico) + clasificación Random Forest	Sentinel-1 (VV, VH), Radarsat-2 (HH), Landsat-8 (NDWI, HSV), texturas GLCM	OA hasta 96.4%, Kappa 0.949, F1 inundación hasta 0.969	- Alta precisión con fusión SAR+ óptico. - Texturas GLCM mejoran límites de inundación. - RF robusto en entornos urbanos y agrícolas.	- Radarsat-2 aporta mejoras limitadas. - Algunas texturas del terreno pueden aumentar ruido si no se combinan bien. - Rendimiento menor en áreas agrícolas complejas.	30 m (todas las capas remuestreadas a 30 m)
	(Li et al., 2024)	Brisbane, Australia	Teledetección, ML aplicado a clasificación multifuente (DT, RF, NB, KNN)	Índices espectrales (NDWI, NDII, dNDWI, CNDWI), PlanetScope, shapefiles de cuerpos de agua	CNDWI fue el más efectivo. Peak-NDWI fue el menos efectivo RF tuvo tiempos de entrenamiento más largos.	- El índice CNDWI, demostró ser efectivo en la detección de inundaciones. - PlanetScope tiene alta resolución temporal y espacial.	- Limitaciones por condiciones climáticas en la obtención de imágenes ópticas. - Costos de imágenes satelitales con alta resolución.	3 metros

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
Método probabilístico / bayesiano	(Zhu et al., 2025)	Japón, Banglades h, EE. UU., China	Modelos hidrológicos + inferencia bayesiana probabilística	TerraSAR-X (banda X), Sentinel-1 (banda C), ALOS-2 (banda L), Gaofen-3, datos hidrológicos, datos de cobertura y uso del suelo.	Precisión: 0.76-0.88, Recall: 0.58-0.83, OA: 0.86-0.92, F1-Score: >0.84.	- Capacidad de reducir falsos positivos. - Mejora la resolución temporal al fusionar datos de diferentes bandas SAR. - No requiere un conjunto extenso de datos etiquetados.	- Dependencia de la disponibilidad de imágenes SAR. - Limitada validación en entornos urbanos y bosques densos. - Menor adaptabilidad frente a métodos de Deep Learning.	ALOS-2: 3 m, Sentinel-1: 10 m, TerraSAR-X: 1.2 m x 3m, Gaofen-3: 10 m.
Métodos híbridos	(Roohi, Ghafouri, et al., 2025)	Río Dez, Irán	Teledetección (GEE), Modelo híbrido: ML tipo ensemble + HEC-HMS + U-Net (DL)	Lluvia, caudal, datos del embalse, parámetros hidrológicos, imágenes satelitales (Sentinel-2, Landsat-8, Landsat-9), Índices espectrales (NDWI, MNDWI, NDMI)	Modelo U-Net para mapeo de áreas inundadas Exactitud: 94.3%-96.4% mIoU: 68.4%-71.3% Precisión: 79%-82.5%	- Mejora significativa la precisión de las predicciones, superando al modelo HEC-HMS. - Capacidad de identificación de eventos críticos. - Integración de múltiples fuentes de datos.	- Dependencia de datos extensos y de alta calidad. - Alta complejidad computacional. - Desafíos en la integración de datos heterogéneos.	Sentinel-2: 10 m Landsat-8: 30 m Landsat-9: 15 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Yan et al., 2023)	China	Teledetección, Modelos hidrodinámicos e hidrológicos, modelos ML y DL (ANN, SVM, RF, RNN), modelos híbridos (modelos físicos + modelos de IA).	Sensor óptico, SAR, LiDAR, DEM (SRTM, ASTER), datos meteorológicos satelitales, datos de sensores en campo, cobertura del suelo, datos históricos de eventos de inundación.	El modelo basado en SVM alcanzó una precisión del 96.5% para diferenciar eventos de inundaciones. Los modelos que utilizaron RF y K-Nearest Neighbor lograron reducciones de errores relativos a menos del 5% en la estimación de áreas inundadas y profundidades.	-Destaca tecnologías emergentes (AI, IoT, big data) - Los modelos híbridos realizan predicciones rápidas y precisas. - La integración de modelos IA superan modelos tradicionales, con mejoras en detección y alerta temprana.	- Los modelos híbridos enfrentan desafíos para optimizar el balance precisión-eficiencia. - Requerimiento de gran cantidad de datos y de alta calidad. - Los modelos híbridos no son generalizables, requiere entrenamiento frecuente.	1–30 m (según sensor: LiDAR 1 m; Sentinel-1 10 m; SRTM 30 m)
	(Sathees Babu et al., 2025)	x	modelo híbrido DL para predicción de profundidad de inundación ICENet (Inception-v3 + CRU-Net + Cross-Attention), DRAW Optimizer	Imágenes satelitales y aéreas; mapas topográficos urbanos; patrones de lluvia; datos hidrológicos; información ambiental y de elevación	AUC 0.99, Accuracy $\approx$ 99%, MSE bajo, RMSE bajo, menor tiempo de entrenamiento e inferencia	-Alta precisión (99%) - Excelente fusión espacial-temporal -Inferencia rápida (1.8 s), robusto frente a escenarios complejos	-No usa caso real validado en campo -Depende de gran cantidad de imágenes de alta calidad	No reporta (usa imágenes satelitales/aéreas, pero no específica resolución)

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Ha et al., 2022)	Vietnam	SIG + teledetección + ML optimizado con BES, SVM, RF, BA, MLP	Sentinel-1A pre/post; 14 variables predictivas, ambientales y sociales	Los modelos híbridos superaron a los modelos individuales en la fase de validación. El modelo con más rendimiento BA-BES, Acc: 0.9159, RMSE: 0.0185, MAE: 0.053. En la fase de prueba RF fue el más eficiente, Acc: 0.93, RMSE: 0.01, MAE: 0.03.	- La combinación de modelos tradicionales con algoritmos de optimización, mejora significativamente el rendimiento de los modelos. - La aplicación de RF mejora la precisión del modelo al reducir la redundancia de datos.	- Limitaciones en las imágenes SAR con factores que afectan la retrodispersión lo que puede generar imprecisiones en la detección de áreas inundadas. - Modelos más precisos, pero que requieren más tiempo para su construcción y optimización.	DEM: 10 m Sentinel-1A:
índices espectrales	(Da Silva et al., 2022)	Argentina	Teledetección, SIG, MDE, Modelización hidrológica, Análisis multicriterio, pan-sharpening	Sentinel-2 (TSUWI), Landsat OLI-TIRS (NDWI, MNDWI), DEM	MNDWI resulta ser el método más adecuado para la detección de inundaciones en zonas urbanas.	- El MNDWI presenta alta sensibilidad para la detección de agua. - Automatización en la clasificación y análisis en la detección de inundaciones.	- Dificultades en la identificación de zonas inundadas en entornos urbanos. - La resolución espacial de estos satélites presenta limitaciones en la identificación de inundaciones pequeñas.	DEM: 5 m Landsat: 30 m Sentinel-2: 10 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Zhran et al., 2024)	Egipto	AHP + SIG + Teledetección (índices e imágenes ópticas)	DEM (ASTER), Landsat-8, Sentinel-2, Índices (NDVI, MNDWI), LULC	AHP, precisión: 74.1% (predicción de zonas de riesgo de inundación).	- Integración de factores heterogéneos (físicos, socioeconómicos). - Integración con SIG para procesamiento espacial y generación de mapas temáticos.	- Pesos asignados por expertos, lo que puede generar variaciones en las salidas gráficas. - No considera variaciones temporales.	DEM 30 metros
	(Hamidi et al., 2023)	Nueva Orleans / Houston-Estados Unidos	Fusión multitemporal SAR, Google Earth Engine	Landsat-8, Sentinel-2, Sentinel-1; índices ópticos (NDWI/MNDWI/NDVI) y SAR (NDFI/RI/DII)	Huracán Harvey 2017, Agr entre SAR y óptico. NDFI: 78%, RI: 80%, DII: 80%. Huracán Ida 2021, Agr entre SAR y óptico. NDFI: 77%, RI: 77%, DII: 80%.	- Proceso de mapeo de inundaciones rápido y automatizable. - Método multifuente que utiliza imágenes SAR y ópticas, utilizando las ventajas de cada fuente. - Método reproducible y replicable. - Alta precisión y sensibilidad.	- Limitaciones en la resolución temporal de las imágenes satelitales. - Dificultades para detectar inundaciones en áreas urbanas debido a efectos de doble rebote. - Los umbrales varían según área geográfica, indicadores e imágenes.	Landsat-8: 30 m Sentinel-1: 10 m Sentinel-2: 10 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(An et al., 2022)	Da Nang, Vietnam	GIS, Teledetección, AHP (Índices de vulnerabilidad: exposición, sensibilidad, capacidad adaptativa)	SRTM DEM (30 m), Landsat-8 OLI (30 m), MNDWI, NDVI, inventario de inundaciones IMHEN, datos socioeconómicos oficiales, OpenStreetMap, Open Data Vietnam	Validación con 52 puntos de campo; correlación con daños reales ($R^2 = 0.79$)	-Marco replicable en zonas con pocos datos -Integra variables físicas y socioeconómicas. -Buena correspondencia con daños reales	-Pesada dependencia de indicadores subjetivos -Ponderación AHP sensible -Variabilidad local alta; resolución limitada a 30 m	30 metros
	(Wu et al., 2023)	China	SAR multitemporal, SIG, índice multiespectral + datos de precipitación	DEM, capas urbanas SIG, MNDWI, MODIS	Estimación del área inundada, Precisión: >90% pérdidas estimadas y datos reales de afectaciones, $R^2: 0.98$	- Detección rápida y oportuna. - Se estiman pérdidas por daños.	- Limitación en la resolución espacial, no es funcional para inundaciones pequeñas. - Dependencia de condiciones climáticas (óptico)	MODIS: 250 m DEM: 30 m
	(Abuhani et al., 2025)	Dubái, Emiratos Árabes Unidos	Teledetección, índices de agua en imágenes satelitales.	Sentinel-2 (NDWI, MNDWI), OpenStreetMap (vías, edificios, infraestructura), puntos críticos (hospitales, clínicas, estaciones de metro, bomberos)	R^2 para evaluar alineación de rutas; porcentaje de áreas inundadas; índice de reachability (capacidad de accesibilidad).	- Uso de datos abiertos -Metodología escalable a otras ciudades -Integración RS + red urbana sin modelos complejos	-Posibles sobreestimaciones por nubes -Dependencia de calidad OSM -Limitado para zonas con infraestructura muy densa	10 m (Sentinel-2)

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Albertini et al., 2022)	Región de Apulia, Italia	Teledetección, métodos de clasificación supervisada y no supervisada (k-means, MLC), GEE	Landsat, Sentinel-2, MODIS, índices espectrales (NDWI, MNDWI), DEM	Validación con 6 eventos históricos; Tasa de aciertos $\geq 80\%$; buena correspondencia espacial entre zonas modeladas e inundaciones observadas	-El uso de GEE, permite procesar información y obtener mapas rápidos tras eventos extremos. - La integración de índices con otros métodos mejora la discriminación de agua y reduce falsos positivos o negativos. - Los índices MNDWI y NDWI son efectivos para la detección de inundaciones.	- Limitaciones en la resolución espacial para detección en áreas urbanas. - Las condiciones atmosféricas adversas pueden afectar la precisión. - Limitaciones con la resolución temporal de las imágenes satelitales.	DEM: 30 metros Landsat: 30 metros Sentinel-2: 10 m MODIS: 250 m
	(Kulk et al., 2023)	India	Teledetección, conocimientos locales, validación cruzada	Sentinel-2 (NDWI/MNDWI, AWEI), Sentinel-1, CHIRPS	Comparación entre satélite óptico- radar y mapas de referencia	- La integración con SAR permite detectar inundaciones en condiciones climáticas adversas. - MNDWI y AWEI son índices que facilitan la detección de agua en entornos complejos.	- La nubosidad y las condiciones climáticas afectan la detección de inundaciones mediante imágenes satelitales. - Ciertas condiciones de las superficies o de la calidad del agua pueden afectar la	10 metros

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
							precisión de los índices utilizados.	
Imágenes satelitales con otros instrumentos	(H. Zhang et al., 2021)	Golestan, Irán	Índice de inundación urbana (UFI), umbrales en imágenes de coherencia Interferométrica (ICD), fusión de coeficientes y coherencias, SVM.	PolSAR Sentinel-1, Jilin-1, Google Earth.	El método UFI mostró mejores resultados. Precisión de detección: 91.09%, Tasa de falsos positivos: 0.95%, Precisión global: 96.93%.	Método UFI - Método no supervisado, no requiere entrenamiento. - Alta precisión y sensibilidad. - Rapidez de cálculo, permite acciones rápidas ante eventos de inundación.	Método UFI - Depende de un umbral fijo. - Sensibilidad a condiciones específicas, como zonas urbanas. - Requiere validación en otras zonas.	Sentinel 1: 10 metros. Jilin—1: entre 0.5 y 2 metros.
	(Alex Immanuel Jeyasingh et al., 2024)	India	SIG, Teledetección, criterios ambientales, datos climatológicos, AHP	Sentinel-1, Sentinel-2, DEM, datos topográficos, hidrológicos, climáticos, cobertura terrestre	x	- El AHP y la superposición de información, permiten la identificación discretizada de zonas de riesgo.	- No considera estructuras del entorno urbano para el mapeo de riesgos, lo que podría mejorar la precisión del mapeo de inundaciones.	x
	(Pelich et al., 2022)	Houston, EE. UU. (Inundaciones por Huracán Harvey, 2017)	InSAR multitemporal; coherencia VV y VH; HSBA (Hierarchical Split-Based Approach); fusión VV–VH; detección	Sentinel-1 (VV/VH); pares pre-evento y co-evento; coherencia interferométrica; Building Mask basada en SAR	Exactitud urbana 75.2% (solo VV) y 82.9% (VV+VH); detección Digital Globe validada; análisis comparativo por polarización	- Aprovecha doble y múltiple rebote. - Mejora detección urbana al combinar VV y VH. - Totalmente automático	- Requiere coherencia estable pre-evento. - Sensible a cambios no debidos a inundación	20 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
			automática no supervisada					
	(Mason et al., 2021)	Reino Unido	Teledetección + filtrado temporal, ajuste hidrodinámico, validación cruzada con modelos	Sentinel-1 SAR; datos hidrodinámicos; registros de nivel de agua; imágenes aéreas	RMSE, comparación con niveles observados, validación temporal	-Mejora consistencia temporal -Reduce falsos positivos -Combina SAR con modelos físicos	-Sensible a errores en nivel del agua -limitada precisión en zonas urbanas densas -Requiere datos auxiliares	Sentinel-1: 10 m
	(Gosset et al., 2023)	Países de África	Teledetección, modelos hidrodinámicos, integración de observaciones satelitales (SAR, óptico, altimetría)	Sentinel-1 SAR, Sentinel-2 óptico, series hidrometeorológicas, datos auxiliares.	Error en la estimación de niveles de agua: ± 50 cm	- Cobertura global y continua. - Detección rápida de eventos de inundación.	- Los sensores ópticos presentan restricciones con condiciones atmosféricas y los SAR con la complejidad de superficies urbanas. - Restricciones en resolución espacial y precisión, para inundaciones pequeñas y eventos de corta duración.	Sentinel-1: 10 m Sentinel-2: 10 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Arias Choquehuanca et al., 2023)	Iquitos, Perú	Detección de cambios, filtrado speckle, umbralización, refinamiento por pendiente y agua permanente	Sentinel-1 SAR (VV, ascendente), 112 imágenes 2015-2021; DEM Hydrosheds; niveles de río SENAMHI; capas JRC; infraestructura SIGRID	Coefficiente de determinación $R^2 > 0.90$ (excepto 2020) entre nivel de río y área inundada	- Procesamiento rápido en GEE. - Acceso gratuito a imágenes. - Continuidad espacial/temporal en eventos de inundación.	- Solo polarización VV disponible en la zona. - Validación limitada por falta de datos in-situ. - Umbral depende de prueba-error.	10 metros (Sentinel-1 GRD)
	(Batmathan et al., 2025)	Malasia	Procesamiento SIG, AHP, análisis estadístico, GEE, índices y umbrales.	Datos del Global Surface Water (GSW), SRTM, Landsat-8, índices (NDVI, NDWI)	No reporta valores; menciona RMSE y R^2 como métricas comunes	- Integración de múltiples fuentes. - El AHP permite la creación de mapas de susceptibilidad confiables en zonas costeras.	- Dependencia de la resolución y calidad de los datos. - Limitaciones de detección en zonas con vegetación densa y grandes áreas urbanas.	Sentinel-1: 10 metros. Landsat-8: 30 metros. SRTM: 30 metros.
	(Roohi, Dehghani, et al., 2025)	Nepal	Teledetección + LiDAR+ Modelo hidrológico + participación comunitaria	Sentinel-2, Landsat	x	- Las imágenes satelitales cubren áreas de difícil acceso. - Integración con otros datos y modelos.	- Limitaciones con la resolución espacial y temporal de las imágenes satelitales.	Sentinel-2: 10 m, Landsat: 30 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
IoT, Sensores	(Van et al., 2025)	Brasil, EE. UU., Australia	Thresholding global (Yen, Otsu, Isodata), thresholding local (Niblack, Sauvola, Gonzalez), métodos híbridos; evaluación de índices espectrales	PlanetScope (8 bandas), índices basados en NIR y RedEdge (incluyendo NDWI, NDVI, NDRE), mapas de referencia creados con Random Forest	MCC >0.9 en mejores combinaciones; FMI >0.9 en híbridos; NDRE con mayor precisión	Métodos rápidos, sin entrenamiento; imágenes 3 m permiten alta precisión urbana; índices con NIR/RedEdge aumentan exactitud	-Sensibles a proporción agua/no agua; -Globales fallan con clases desbalanceadas; -Locales pueden generar ruido; requiere optimizar parámetros	3 metros
	(Goyal et al., 2021; Souza & de Amorim Silva, 2025)	Mumbai, India	ANN (Artificial Neural Network) combinada con datos IoT en drenaje urbano	Datos meteorológicos históricos y en tiempo real; sensores IoT (flujo, presión, obstrucciones)	x	- Análisis y toma de decisiones en tiempo real con alta precisión. - Integración de parámetros dinámicos.	- Complejidad de integración de datos para análisis en tiempo real. - La resolución espacial depende de la densidad y tipo de sensores.	x
Tecnología (UAV / LiDAR)	(Akinsoji et al., 2024; Osco et al., 2021)	Contexto urbano general	UAV con cámaras RGB y multiespectrales, Deep Learning (CNNs)	Imágenes UAV de alta resolución; análisis multitemporal; integración con DEM para evaluación de riesgo.	x	- Los modelos DL, permiten procesos eficientes y automatizados, para extraer información precisa de datos obtenidos con UAVs. - DL tiene adaptabilidad a diferentes sensores.	- Recursos computacionales elevados. - DL requiere de gran cantidad de datos etiquetados para ser entrenado.	x

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Roohi, Dehghani, et al., 2025)	Los Andes-Sudamérica	UAVs + LiDAR	Nube de puntos LiDAR; DEM de alta precisión; identificación de cambios geomorfológicos, zonas vulnerables y daños post-evento.	x	- Genera insumos de alta resolución espacial. - Mejora la accesibilidad a zonas de difícil acceso. - Las imágenes se obtienen a demanda, mejora tiempos de identificación y respuesta.	- Alcance limitado para cubrir grandes áreas. - Dependencia de las condiciones climáticas para la captura de información.	x
	(Malinverni et al., 2025)	Italia (ríos Metauro y Cesano)	LiDAR aerotransportado + GNSS para validación	DSM/DTM; ortofotografía digital.	x	- Integración con modelos hidrodinámicos para estimar niveles de agua. - Insumos confiables para modelos hidráulicos.	- Dependiente de condiciones meteorológicas. - Costos elevados asociados a la adquisición y procesamiento.	1 metro
	(Bolick et al., 2023)	Hunnicutt Creek, Carolina del Sur	LiDAR terrestre (mochila) + ML (Prophet)+ modelado 3D	DEM; datos de sensores de nivel, estaciones meteorológicas y datos de calidad del agua.	Todas las estaciones lograron valores de coeficiente de determinación $R^2 > 0.9$ (el desempeño varía en función de la cantidad y tipo de variables)	- Integra múltiples datos como nivel de cuerpos de agua, estaciones meteorológicas y calidad del agua. - Flexibilidad y simplicidad del modelo. - visualización de cambios en niveles de agua en modelo 3D.	- Limitación espacial y temporal (la extrapolación a otras cuencas no es automática). - Alta resolución que demanda recursos computacionales, clasificación adecuada y	DEM 3- 18 cm

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
							validación en campo.	
Revisión (varios métodos)	(Bolick et al., 2023)	Revisión global (técnicas SAR en varios países)	Umbralización, lógica difusa, ML (RF, SVM, Gradient Boosting), Deep Learning (U-Net, ResUNet, SegNet, Siamese Nets), fusión SAR-óptico-LiDAR, modelos probabilísticos (Kalman, Particle Filter)	SAR bandas C/L/X; Sentinel-1; TerraSAR-X; ALOS-PALSAR; TanDEM-X; datos ópticos y LiDAR; datasets abiertos	OA, Precisión, Recall, IoU, F1-Score, PWRMSE (no reporta valores numéricos)	-Operativo día/noche -Útil en todo clima -Alta sensibilidad al agua -Amplia disponibilidad de datos; ML/DL con buen desempeño; fusión mejora exactitud	-Problemas en vegetación densa -Errores por escala/sombra en zonas urbanas -Requiere preprocesamiento intenso. - Los modelos DL requieren muchos datos para entrenamiento.	Sentinel-1: 10 m Sentinel-2: 10 m TerraSAR-X: 3 m (modo alta resolución) TanDEM-X/TerraSAR-X: hasta 3 metros. Satélites comerciales, alta resolución.
	(Schumann et al., 2023)	Revisión global	Imágenes ópticas (NDWI), SAR (intensidad, coherencia, polarimetría), detección de cambio, Active Contour Models, region growing, ML/DL (U-Net, CNNs), altimetría, radiometría microondas,	Óptico (MODIS, Landsat, Sentinel-2), SAR (Sentinel-1, TerraSAR-X, ALOS-PALSAR), altimetría (ICESat, Sentinel-3, CryoSat-2, Jason), microondas pasivo (AMSR-E, GPM), DEM LiDAR, datos hidrológicos y modelos hidráulicos 1D/2D	No reporta métricas numéricas; describe métricas comunes: OA, precisión, recall, IoU, F1; y desempeño de modelos mediante validación por extents, niveles de agua y ajuste entre modelos—Earth Observation	Amplia cobertura espacial; EO útil en día/noche -SAR penetra nubes y vegetación -Integración EO—modelos mejora predicción; altimetría complementa zonas sin aforos -Datos abiertos de alcance global	-Limitaciones en sensores ópticos por condiciones climáticas. -Problemas SAR por escala/sombra; -Incoherencias en vegetación y áreas urbanas	Varía según sensor: óptico 10–30 m; SAR 3–20 m; MODIS 250 m; altimetría (píxel amplio, 50–300 m)

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
			integración EO + modelos, data assimilation (EnKF, Particle Filter)					
	(Bentivoglio et al., 2021)	Revisión global de 58 estudios DL para mapeo de inundaciones	CNN (2D/3D), MLP, RNN/LSTM, encoder-decoder, segmentación (U-Net/variantes), 1D CNN para secuencias, modelos híbridos ML+DL	Datos ópticos (Landsat, Sentinel-2, MODIS), SAR (Sentinel-1, TerraSAR-X, ALOS-PALSAR), UAV, DEM, lluvia, hidrogramas, simulaciones hidráulicas 1D/2D	No reporta valores; menciona uso común de F1-Score, IoU, Recall, Accuracy, AUC, RMSE, R ²	-DL permite la detección automatizada y precisa en la delimitación de áreas urbanas. - rapidez y escalabilidad de los modelos. - Integración de múltiples fuentes de datos.	- Dependencia de datos de alta calidad y resolución. - Limitaciones para los sensores ópticos ante condiciones climáticas adversas. - Alta capacidad computacional y gran cantidad de datos de entrenamiento.	Landsat: 30 metros Sentinel-1: 10 metros Sentinel-2: 10 metros.
	(Islam et al., 2025)	Revisión global (120 estudios sobre susceptibilidad a inundaciones urbanas)	MCDA (AHP), ML (RF, SVM, ANN), DL (CNN), análisis morfométrico, integración SIG + RS	Sentinel-1, Sentinel-2, Landsat, SRTM, LiDAR, CHIRPS (precipitación), datos urbanos y uso del suelo	No reporta métricas numéricas; menciona F1, IoU, AUC, OA según estudios revisados	- Integración de múltiples métodos. - Identifica brechas globales. - lineamientos para mejorar análisis urbanos	-Alta heterogeneidad entre estudios -Falta de estandarización -limitada aplicabilidad sin ajuste local.	10–30 m (según sensor usado en los estudios)
	(Hlal et al., 2025)	Revisión global (85 estudios)	Integración Digital Twin + RS + IoT; fusión	Sentinel-1, Sentinel-2, Landsat, UAV,	x	-Integración en tiempo real -Visión global de	-Alta demanda computacional -Falta de	UAV/LiDAR: resolución

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
		2018–2025)	multisensor; ML/DL (RF, XGBoost, U-Net, LSTM); modelos hidrodinámicos; simulación en tiempo real	LiDAR, IoT, CHIRPS; modelos 1D/2D; datos crowdsourcing		tecnologías -Mejora pronóstico y alerta	estándares -Desigualdades de datos en países vulnerables	de centímetros. Sentinel-1 y 2: 10 metros. Landsat 8 y 9: 30 metros
	(Iqbal et al., 2023)	Revisión global (estudios sobre drones en inundaciones)	Bibliometría; análisis de tendencias; UAV + sensores remotos; ML/DL para detección; fotogrametría + LiDAR; clasificación basada en visión por computador	UAV RGB, LiDAR, sensor, térmico, SAR, imágenes ópticas; DEM; registros hidrológicos; WoS database	No reporta valores; menciona uso de F1, IoU, OA y correlación en estudios revisados	- Visión global del estado del arte - Identifica tendencias emergentes - UAV como plataforma eficiente y flexible.	- Heterogeneidad alta entre estudios. - Falta estandarización. - Limitada validación en escenarios reales.	UAV cm–metros; LiDAR ~1 m; sensores satelitales 10–30 m
	(M. Zhang et al., 2025)	Revisión global (NASA Disaster Mapping System – DMS)	Integración RS + modelos; fusión multisensor; mapeo automatizado; análisis multitemporal; visualización 2D/3D; pipelines NASA (SAR, óptico, altimetría)	Sentinel-1, Sentinel-2, Landsat, MODIS, VIIRS, UAV/SAR, DEM, datos hidrometeorológicos, modelos de inundación	No reporta métricas numéricas; menciona exactitud, coherencia EO–modelos y validaciones internas	- Plataforma global y operativa. - Integración de múltiples sensores - Productos rápidos para respuesta a desastres.	- Dependencia de datos satelitales - Limitaciones SAR en entornos urbanos. - Resoluciones heterogéneas.	3–30 m (según sensor); MODIS 250 m; UAVSAR <3 m

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Anik et al., 2025)	Revisión global (ML para exposición y daños por inundación)	ML (RF, SVM, ANN, XGBoost), DL (CNN, LSTM), modelos híbridos, análisis de impacto, regresión y clasificación	Datos ópticos (Landsat, Sentinel-2), SAR (Sentinel-1), DEM, lluvia, uso del suelo, datos socioeconómicos, registros de daños	Menciona métricas como RMSE que puede variar entre 0.03-0.09, exactitud 95%-99%, tiempo de computo y coeficiente de correlación (CC).	Visión completa del estado del arte; identifica mejores algoritmos; integra variables físicas y socioeconómicas	-Falta estandarización de metodologías -Alta variabilidad entre datasets -Escasez de datos confiables en regiones críticas	10–30 m (según sensor usado en los estudios)
	(Liu et al., 2025)	Revisión global (108 estudios)	Machine Learning (RF, ANN, CNN, SVM, LSTM, U-Net, XGBoost, YOLO); modelos híbridos; ML + RS; ML + modelos físicos	Datos de campo (sensores), simulaciones hidrodinámicas, imágenes SAR/ópticas, LiDAR, VGI, redes sociales	No reporta métricas propias; sintetiza métricas usadas en estudios: RMSE, MAE, R ² , NSE, F1, IoU, OA, Kappa	- Alta precisión respecto métodos tradicionales. - Métodos rápidos que facilitan respuestas rápidas ante eventos. - Integración de múltiples fuentes de datos.	-Dependencia de cantidad y calidad de datos. -Baja interpretabilidad. - Modelos no generalizables, dado que se entrenan ante condiciones específicas.	Variable según fuente: sensores (puntual), UAV cm–m; satélite 10–30 m; LiDAR ~1 m
	(Waseem & Rana, 2023)	Revisión nacional (Pakistán, 2010–2022)	SIG, Teledetección, Análisis de Jerarquía Analítica (AHP), lógica difusa, redes neuronales, enfoques de toma de decisión.	601 artículos Scopus; palabras clave; metadatos; indicadores sociales, económicos y ambientales	Índice de vulnerabilidad multidimensional, índice de vulnerabilidad climatológica, índice de resiliencia.	- Panorama completo de investigación en Pakistán - Identifica vacíos - Integra múltiples disciplinas	- Alta heterogeneidad de estudios - Limitado a Scopus y artículos en inglés	No aplica (estudio de revisión; usa múltiples resoluciones según estudios: 10–30 m)

Categoría metodológica	Artículo	Caso	Métodos principales	Datos utilizados	Métricas de evaluación	Ventajas	Desventajas	Resolución espacial
	(Chitwat kulsiri & Miyamoto, 2023)	Sudeste Asiático (revisión regional)	Revisión de modelos tiempo real; radar + nowcasting; modelos hidráulicos 1D–2D; AI (ANN, CNN, LSTM, GRU)	Datos de radar; pluviómetros; satélite; DEM/LiDAR; drenajes urbanos; modelos SWMM/MIKE; datos históricos	No aplica (artículo de revisión, no reporta métricas)	Visión completa del estado del arte; identifica limitaciones de datos; propone enfoque híbrido	-Falta de datos de drenaje -Alto costo computacional -Capacidad limitada en ciudades del Sudeste Asiático	Radar ~1 km; DEM 1–5 m; modelos urbanos (variable según fuente)
	(Zhao et al., 2025)	Revisión global	Inspección visual, Umbrales, Lógica difusa, Segmentación de imágenes, ML (SVM, RF), DL (Red UNet)	SAR (varias bandas), PolSAR, InSAR, DEM,, imágenes ópticas (UAV, satélites).	Basado en estudios. Exactitud > 85% (estudios que combinan coherencia, intensidad y datos auxiliares). F1-Score: entre 0.75-0.9 (técnicas automatizadas y umbralización)	- Implementar información de coherencia InSAR mejora la detección y clasificación de áreas inundadas. - Satélites de nuevas generaciones, permiten detectar detalles en áreas urbanas y reducir efectos como doble rebote característico de zonas urbanas.	- Dependencia de datos de entrenamiento. - Limitaciones de resolución espacial y temporal y de costos asociados a satélites comerciales.	Sentinel-1:10 m Sensores comerciales: 1-3 metros

En la Tabla 2, se aprecia un gradiente de complejidad metodológica, que va desde enfoques relativamente simples (umbrales, detección de cambios, índices espectrales), hasta arquitecturas avanzadas de Deep Learning y modelos híbridos que integran teledetección, SIG, hidrología, IoT y datos espaciales. Las metodologías más recientes integran múltiples fuentes de información y reportan un amplio conjunto de indicadores de desempeño, que permiten comparar métodos y seleccionar los que tengan mejor rendimiento.

El segundo patrón aparente se refiere a la resolución espacial y escala de análisis. Las técnicas basadas en imágenes de resolución media (Landsat, Sentinel), están orientadas a estudios regionales o análisis de tendencias de largo plazo; mientras que los enfoques aplicados en áreas urbanas dependen de resoluciones más finas (PlanetScope, sensor TerraSAR-X, e incluso resolución de centímetros con instrumentos LiDAR y UAVs). A medida que aumenta la resolución, también lo hace la capacidad de detectar inundaciones localizadas y examinar afectaciones en la infraestructura, pero al mismo tiempo, el volumen de información y los requisitos computacionales aumentan. Se identifica que gran parte de los casos de estudio, integran múltiples fuentes para mejorar el rendimiento y generar mapas de inundación más confiables.

Finalmente, se encuentra que los métodos e instrumentos empleados dependerá de los recursos que se disponen y de la necesidad de precisión para la detección y mapeo de inundaciones; de esta manera, si se dispone de datos de múltiples fuentes, capacidad de cómputo y la necesidad de alta precisión, el enfoque debe dirigirse a la integración de datos con herramientas como machine learning, Deep learning o modelos de ensamblaje. Mientras que métodos no supervisados como detección de cambios, umbrales e índices espectrales siguen siendo alternativas viables en casos con limitaciones de recursos que necesitan rapidez, reproductibilidad e imágenes satelitales accesibles. Más que una "técnica ideal", la Tabla 2 sugiere un portafolio de opciones cuya relevancia depende de la escala, la disponibilidad de datos, el objetivo del análisis y las capacidades institucionales de cada territorio, y debe ser evaluada a través de dicho análisis comparativo.

Discusión

La discusión crítica tiene como propósito interpretar y unir los hallazgos de la matriz bibliométrica, para explicar no sólo qué métodos utilizan los estudios, sino también comprendiendo que significan estas metodologías para el análisis de inundaciones urbanas, qué tan útiles son, en qué contextos funcionan mejor y cuáles son sus principales limitaciones. A través de esta revisión se presentan algunos instrumentos y algoritmos como sensores remotos, SIG, aprendizaje automático, modelos probabilísticos o análisis de infraestructura y como contribuyen a partes específicas del problema. La integración de estos elementos permite una visión más realista del riesgo.

Los estudios incluidos revelan que las inundaciones urbanas son un fenómeno complejo donde interactúan factores físicos, territoriales y sociales. La revisión permite encontrar patrones recurrentes, brechas metodológicas, desafíos técnicos y predominantemente, cómo el desarrollo de las ciudades influye directamente en la severidad de estos eventos. Tal evaluación crítica, entonces, no solo añade a nuestro conocimiento de los resultados, sino que aclara por qué ocurrieron los eventos, qué enfoques funcionan mejor en diferentes tipos de territorio, qué sensores son preferidos

para su uso en entornos adversos y cómo las dimensiones humanas podrían haber sido ignoradas si la discusión se hubiera restringido sólo a la teledetección.

En síntesis, este apartado busca ofrecer una mirada integral, comparativa y reflexiva sobre las tendencias metodológicas revisadas, destacando sus fortalezas, sus debilidades y su contribución real para interpretar el riesgo de inundaciones en contextos urbanos.

Inundaciones en contextos urbanos

Las inundaciones se han convertido en una problemática cada vez más visible, debido a la forma en que las ciudades crecen y ejercen presión sobre el territorio. La literatura revisada coincide en que la expansión acelerada, la impermeabilización de grandes superficies y la ocupación informal de zonas expuestas son las fuerzas definitorias que amplifican la intensidad de estos eventos. En (An et al., 2022) se menciona que la expansión urbana hacia zonas bajas ha aumentado significativamente la exposición a inundaciones en los últimos años, una situación similar ocurre en el Gran Resistencia, Argentina, donde el crecimiento llevó a la ocupación de zonas inadecuadas, por lo que son vulnerables a la ocurrencia de inundaciones (Da Silva et al., 2022)

En ambos casos se muestra cómo la urbanización sin regulación adecuada termina aumentando riesgos que podrían ser evitables. Por otro lado, la problemática de las inundaciones urbanas también está vinculada a la heterogeneidad de las superficies construidas, en zonas densamente edificadas, estos techos, pavimentos, muros y estructuras metálicas generan respuestas espectrales muy variables, lo que hace que la detección remota del agua sea un desafío; En (Li et al., 2024) se señala que los entornos urbanos contienen una mezcla de casas, apartamentos, carreteras, parques, jardines y piscinas, lo que hace que la detección de inundaciones sea más difícil. Este desafío está estrechamente alineado con lo planteado por Tanim et al., (2022), que señalan tres retos críticos: 1) inundaciones efímeras, 2) superficies urbanas complejas y 3) cuerpos de agua fragmentados.

La literatura más allá de sus elementos físicos también muestra que las inundaciones urbanas son un fenómeno profundamente social, Bai et al., (2021) señalan que representan alrededor del 46% de los desastres naturales en todo el mundo, y afectan de forma recurrente a poblaciones de bajos ingresos, que a menudo suelen habitar en zonas más expuestas. Esto se puede evidenciar en eventos extremos como las inundaciones monzónicas de Pakistán, que en 2022 afectaron a 33 millones de personas y desplazaron a 5,4 millones (Waseem & Rana, 2023). Las inundaciones urbanas no pueden examinarse solo en el marco de la hidrología o la infraestructura; deben incluir la vulnerabilidad social, la vivienda precaria y las desigualdades territoriales.

En América Latina hay investigaciones sobre la misma conexión entre el crecimiento urbano y la exposición al riesgo. En Iquitos, Perú, Arias-Choquehuanca (Arias Choquehuanca et al., 2023) describe cómo la ciudad está íntimamente conectada con los ríos Itaya, Nanay y Amazonas, lo que hace que las inundaciones sean recurrentes y estructurales. La vulnerabilidad aumenta debido al crecimiento desorganizado, la falta de obras públicas adecuadas y la ocupación informal de tierras, un patrón que se repite en muchas ciudades de la región.

En síntesis, todos estos estudios coinciden en que las inundaciones urbanas no pueden entenderse desde un único factor, son resultado de una interacción compleja entre 3 grandes factores: 1)

físicos (lluvias extremas, drenajes insuficientes), 2) territoriales (urbanización acelerada, ocupación informal de zonas de riesgo) y 3) sociales (pobreza, desigualdad, falta de adaptación). Esta multidimensionalidad implica que la gestión o el estudio de las inundaciones no puede limitarse a mapear agua, sino que se comprenda cómo el territorio se transforma, quiénes son los más afectados y qué elementos estructurales del espacio urbano intensifican los impactos. Por lo que, integrando estas dimensiones ambientales, sociales y tecnológicas, es posible desarrollar análisis más completos y estrategias efectivas de mitigación.

Sensores remotos aplicados al estudio de inundaciones

Las investigaciones recientes muestran que los sensores remotos se han convertido en una pieza esencial para comprender, anticipar y mapear inundaciones, especialmente en áreas urbanas donde las condiciones cambian con gran rapidez y la información disponible en terreno casi no es suficiente. Lo que llama la atención es que, aunque los estudios utilizan tecnologías muy diferentes, como; ópticas, radar, multiespectrales, drones, LiDAR, entre otras, todos coinciden en algo, ningún sensor por sí solo es suficiente, y cuando se combinan múltiples fuentes de información aparecen los mejores resultados.

Un punto en común en la literatura es la preocupación por la rápida dinámica de las inundaciones urbanas, donde los encharcamientos o flujos intensos duran pocas horas, Tanim et al., (2022) los llaman “*inundaciones molestas*” y explica que, por su corta duración, son difíciles de detectar, sobre todo si ocurren en medio de lluvia o nubosidad, lo que limita el uso de sensores ópticos. Por esto, cada vez más estudios utilizan el radar de apertura sintética (SAR), que puede observar incluso en condiciones meteorológicas adversas. Esto lo resume (Wu et al., 2023) al señalar que la retrodispersión SAR es sensible a las superficies inundadas, incluso bajo cobertura de nubes, algo crítico en zonas tropicales o monzónicas.

Aun así, el radar tampoco es perfecto. En áreas urbanas densas, las múltiples reflexiones que generan los edificios, los carros o las estructuras metálicas producen patrones muy complejos, Gokon et al., (2023), Menciona que las zonas urbanas presentan mecanismos de dispersión complejos que dificultan la detección de inundaciones; aunque existen alternativas más estables, como las señales en banda L del ALOS-2, muchos estudios prefieren trabajar con estrategias híbridas: combinan polarizaciones VV y VH (Pelich et al., 2022), emplean índices como VV/VH (H. Zhang et al., 2021) o fusionan intensidad y coherencia para mejorar las detecciones.

Por el contrario, los sensores ópticos siguen siendo un componente importante, a pesar de sus limitaciones, su principal fortaleza es el nivel de detalle espacial que ofrecen, lo que permite detectar cambios sutiles en el paisaje, especialmente cuando se dispone de imágenes de alta resolución. La investigación de Van et al., (2025) resalta el valor de PlanetScope por su resolución espacial de 3 metros por píxel y a su revista diaria, características que hacen posible capturar inundaciones repentinas. De manera complementaria, Li et al., (2024) muestran que índices como el NDII pueden detectar variaciones rápidas en el infrarrojo cercano durante un evento, aunque advierten que en contextos urbanos pueden presentarse imprecisiones notables debido a la resolución y diversidad de características. Cada vez más estudios coinciden en que las soluciones que integran varias fuentes ofrecen los mejores resultados, Bai et al., (2021) evidencian que la combinación de Sentinel-1 y Sentinel-2 con algoritmos de aprendizaje profundo mejora

significativamente la detección tanto de agua permanente como de inundaciones temporales. Además, conjuntos de datos especializados como Sen1Floods11 (Bonafilia et al., 2020) se han convertido en una referencia clave para entrenar modelos capaces de analizar inundaciones en distintas realidades.

Los avances más recientes también apuntan hacia una integración más completa entre sensores remotos, modelos de aprendizaje profundo y datos hidrológicos. Mohamadiazar et al., (2024) destacan que uno de los grandes desafíos actuales es mejorar la resolución temporal y contar con información en tiempo real, incorporando variables como la precipitación o la humedad del suelo para afinar las predicciones. Así mismo, Roohi, Ghafouri, et al., (2025) proponen modelos híbridos que combinan principios físicos, datos satelitales y redes neuronales, con el fin de anticipar de manera más realista el comportamiento de las inundaciones.

En los últimos años también han cobrado relevancia los drones. Iqbal et al., (2023) muestra que los UAV (Unmanned Aerial Vehicles- Vehículos no tripulados) permiten suplir muchas limitaciones de los satélites: entregan imágenes de muy alta resolución, pueden capturarse justo después del evento y pueden equiparse con sensores muy variados (RGB, LiDAR, térmico). Esto es particularmente útil en ciudades complicadas o con nubosidad persistente, porque los drones permiten observar lo que los satélites no alcanzan a registrar.

En términos más amplios, las revisiones generales muestran que estamos viviendo una etapa de transición tecnológica. Schumann et al., (2023) señalan que hoy existe una amplia diversidad de sensores ópticos, SAR, altimétricos y de microondas pasivas, que permiten analizar las inundaciones desde distintas escalas y perspectivas. Por su parte, Bentivoglio et al., (2021) explican que los algoritmos de aprendizaje profundo funcionan mejor cuando integran información de múltiples sensores, en lugar de depender de una sola fuente. Finalmente, estudios como el de Kumari et al., (2025) muestran que los sensores ópticos capturan detalles superficiales muy útiles, mientras que el radar aporta información complementaria en momentos en los que la nubosidad, la hora del día, o la lluvia dificultan la observación óptica.

La literatura concluye que los sensores remotos son un elemento clave en la gestión de inundaciones urbanas. Es decir, al decidir entre radar u óptico, o entre satélite y dron, el enfoque está en cómo combinarlos y cómo beneficiarse de sus ventajas para obtener información más útil y oportuna. La preferencia dominante en la actualidad apunta a métodos híbridos, multitemporal y multisensor, los cuales son capaces no sólo de detectar dónde hay agua, sino también de entender cómo evoluciona la inundación, cuánta profundidad podría tener y qué impactos reales genera sobre las ciudades y sus habitantes.

Sistemas de Información Geográfica (SIG) en el análisis de afectaciones urbanas

Los Sistemas de Información Geográfica (SIG) se utilizan ahora como una herramienta clave para comprender cómo las inundaciones afectan a las zonas urbanas. Aunque cada estudio utiliza diferentes métodos, todos coinciden en que los SIG pueden ayudar a recopilar información que normalmente está dispersa (imágenes satelitales, modelos digitales de elevación, redes viales, uso del suelo, edificios, sistemas de drenaje y otros) y combinarla en un espacio de trabajo analítico

único. Esta integración es esencial, porque las inundaciones urbanas no dependen solo del agua, sino también de la forma en que está construida la ciudad, sus pendientes, el estado de sus sistemas de drenajes y la densidad de la población.

Antes de modelar una inundación o mapearla, los estudios exponen que hay que “preparar” digitalmente el territorio, puesto que, una parte importante del trabajo ocurre directamente en el SIG: reclasificar capas, calcular distancias, generar pendientes o derivar rutas de escorrentía. Esto queda muy claro en An et al., (2022), quienes señalan que el SIG sirve como entorno central para la integración espacial, la superposición y la cartografía de vulnerabilidades. Es una idea que resume bien el enfoque general de estos trabajos.

Otros autores, como Alex Immanuel Jeyasingh et al., (2024); Zhran et al., (2024), aplican esta lógica de manera práctica. Usan datos de lluvia, uso del suelo, drenajes y densidad urbana, y los combinan en ArcGIS para generar mapas de susceptibilidad. Aunque trabajan en contextos diferentes, ambos coinciden en que la fortaleza del SIG está en su capacidad para reunir múltiples capas y ofrecer una visión más completa del riesgo. Incluso en estudios más rurales como Kulk et al., (2023) se resalta que el SIG organiza la información espacial y facilita escalar resultados hacia zonas pobladas.

Algunos trabajos enfatizan particularmente la evaluación de daños. Wu et al., (2023) explican que se incorporaron capas SIG para refinar los límites de inundación y evaluar la exposición de los bienes urbanos. Esto supone integrar datos de edificaciones, redes viales, infraestructura crítica y usos del suelo, práctica que se ha repetido en estudios recientes basados en UAV, como (Iqbal et al., 2023), donde los SIG se utilizan para construir modelos digitales, mapas de afectación y análisis por sectores.

El SIG también es importante en la topografía compleja de las regiones urbanas. Amitrano et al., (2024) enfatiza la necesidad de realizar modelos digitales de elevación (DEM) dentro del SIG para corregir distorsiones como la escala y la sombra en imágenes SAR en ciudades que se encuentran en pendientes o están altamente urbanizadas. Es similar a lo descrito por Schumann et al., (2023) que el SIG se utiliza para calibrar modelos, cruzar datos hidrológicos y validar mapas de inundaciones basados en sensores remotos.

La combinación de SIG y aprendizaje automático aparece como una tendencia bastante fuerte. Bentivoglio et al., (2021) argumentan que los datos SIG pueden cooperar al entrenamiento de modelos de aprendizaje profundo, se requiere que las capas generadas en SIG, incluyan: pendiente, curvatura, índice topográfico, distancias a ríos o carreteras que ayudan a entender cómo la forma urbana influye en el comportamiento del agua. Esto se refleja en evaluaciones anteriores como (Hlal et al., 2025; Islam et al., 2025) quienes destacan que la intersección entre datos físicos y sociales dentro del SIG permite representar mejor el riesgo urbano.

El SIG también juega un papel importante en contextos con infraestructura crítica. Al conectar datos de OpenStreetMap con índices de agua y redes viales, se pueden realizar cálculos para rutas afectadas, segmentación de calles y análisis de conectividad urbana en un entorno de emergencia (Abuhani et al., 2025). Por otro lado, Mason et al., (2021) armonizan mapas SAR con mapas oficiales de riesgos para identificar discrepancias, produciendo datos más consistentes para la toma

de decisiones, trabajos como (Pelich et al., 2022) o (H. Zhang et al., 2021) ilustran muy bien cómo el SIG lleva los resultados del radar a un análisis territorial, permite superponer capas clasificadas con ríos, edificios, límites administrativos o calles, y evaluar la calidad de los mapas mediante métricas espaciales. En ciudades complejas, donde cada calle modifica el flujo del agua, estos análisis son necesarios. Métodos aún más amplios, por ejemplo, el de Liu et al., (2025), muestran que los SIG no solo sirven para mapear inundaciones, sino también para integrar variables. Batmanathan et al., (2025) evidencian que la plataforma SIG es capaz de conectar procesos distintos como hundimientos y exposición a inundaciones para crear escenarios urbanos más completos.

En síntesis, los SIG funcionan como un enlace entre los datos y la ciudad real. No solo ayudan a ver dónde ocurre una inundación, sino también a entender por qué, qué elementos de la estructura urbana agravan el riesgo y qué poblaciones o infraestructuras son más vulnerables. La literatura es clara: en el análisis y la gestión del riesgo de inundaciones urbanas, el SIG no es solo un software para hacer mapas; es un espacio de integración donde la ciudad puede leerse de manera espacial, dinámica y críticamente.

Infraestructura urbana y afectaciones

La infraestructura urbana es una de las cosas que más ilustra la desigualdad cuando se trata de inundaciones. No todas las áreas se ven igualmente afectadas cuando llega el agua. La literatura revisada indica que los daños se concentran en gran medida en áreas de alta densidad de edificaciones con sistemas de drenaje limitados y ocupación de tierras apresurada. En muchos casos, las inundaciones son devastadoras no solo para los edificios, sino también para las dinámicas, como la movilidad y los servicios. Un caso que ilustra esto es descrito por Van et al., (2025), señalando el impacto de los eventos en carreteras, infraestructura y servicios, lo que a su vez muestra que las inundaciones urbanas causan pérdidas económicas sustanciales y alteran la infraestructura crítica.

Cuando las lluvias alcanzan extremos, el deterioro de la infraestructura no se hace evidente únicamente como resultado de lluvias extremas, Da Silva et al., (2022) lo explican como el poco desarrollo de obras de infraestructura destinadas a mitigar los efectos que agravan las problemáticas ambientales. Esto se también se ve en estudios de Egipto (Zhran et al., 2024), donde la vulnerabilidad aumenta cuando las vías, hospitales y sistemas urbanos se encuentran expuestos sin adaptaciones suficientes.

En zonas densamente urbanizadas, la infraestructura cumple un doble propósito, además de ser una de las principales afectadas durante una inundación, también ayuda a decidir cómo se mueve el agua dentro de la ciudad. El estudio de Hlal et al., (2025) lo muestra con claridad: el drenaje insuficiente, los obstáculos propios del entorno urbano y la canalización forzada del flujo pueden intensificar la inundación y aumentar los daños en las vías y las edificaciones. Incluso en investigaciones más técnicas, como el de Amitrano et al., (2024), se señala que las estructuras urbanas afectan la lectura de los sensores remotos, generando sombras, rebotes múltiples y sectores donde la inundación puede pasar desapercibida.

Un punto importante destacado por la literatura es la vulnerabilidad de la infraestructura urbana central, aquella que sostiene el funcionamiento diario de la ciudad. Abuhani et al., (2025) advierten que, durante una inundación, los centros de salud pueden quedar completamente aislados si las vías principales se bloquean y no existen rutas alternativas. Esto hace que una emergencia médica sea un escenario de alto riesgo. Sus hallazgos sobre la situación en Dubái son, por lo tanto, sorprendentemente ilustrativos: a pesar de que la ciudad tiene una infraestructura moderna y de alta calidad, su diseño no garantiza resiliencia si depende de pocos corredores viales estratégicos; también aumentan la preocupación sobre la interconectividad entre la degradación de los sistemas de transporte, el comercio y las instalaciones públicas y crean efectos en cadena que influyen en la estructura urbana en su conjunto. Por ejemplo, cuando una carretera se inunda o se detiene la provisión de rutas de transporte, no solo las personas son desplazadas, los bienes se interrumpen, el acceso a los mercados y servicios se reduce. Esto ralentiza la recuperación y extiende las disparidades, con áreas con menor acceso o servicios alternativos permaneciendo vulnerables por más tiempo.

Las investigaciones también confirman que las inundaciones no afectan a todas las edificaciones por igual. M. Zhang et al., (2025) enfatizan la necesidad de precisar el número estimado de edificios afectados y las tendencias espaciales del daño, porque esto permite entender cómo los impactos suelen concentrarse en ciertos puntos de la ciudad, como en barrios con alta densidad, zonas cercanas a drenajes insuficientes o sectores donde las viviendas se han levantado en áreas bajas y propensas al anegamiento. Esta idea se refuerza en el caso peruano investigado por Arias Choquehuanca et al., (2023), donde se observa que barrios enteros están sujetos a múltiples efectos a la vez (tanto las viviendas, carreteras y escuelas, como los centros de salud). Lo que este tipo de estudios pone en evidencia es la dimensión humana del daño: no se trata solo de estructuras inundadas, sino de comunidades completas cuya vida cotidiana queda interrumpida.

Una dimensión adicional subrayada por la literatura se centra en las zonas costeras y la susceptibilidad de la infraestructura estratégica. (Batmanathan et al., 2025) evidencian que, en Selangor, Malasia, la combinación entre subsidencia y eventos de inundación expone hasta el 34 % del área urbanizada, lo que incluye instalaciones clave como puertos, aeropuertos y polígonos industriales. Una segunda característica de su estudio es que el daño no siempre es inmediato: lleva tiempo llegar allí en forma de grietas, subsidencia o, más lentamente, la desaparición o el desgaste lento de carreteras y edificios funcionales.

En la literatura también se utilizan métodos tecnológicos que permiten interpretar mejor los daños en la infraestructura. Zhu et al., (2025) destacan que, al aumentar la precisión con la que se delimitan las zonas inundadas es posible identificar con mayor detalle qué infraestructuras críticas resultaron afectadas, lo que facilita una toma de decisiones más rápida durante la fase de respuesta. De la misma manera, los enfoques de aprendizaje profundo revisados por Anik et al., (2025); Mohamadiazar et al., (2024) reconocieron que la capacidad de un sistema de drenaje urbano o la densidad de edificios son aspectos clave que afectan directamente el grado de modelado exitoso, y que las ciudades deben modelarse de una manera más realista y condicionada a las especificidades del territorio.

Por último, Cerbelaud et al., (2023) enfatizan la importancia de diferenciar entre tipos de daños: aquellos productos del desbordamiento fluvial y aquellos originados por la escorrentía pluvial

sobre pavimento, parcelas o taludes. Esta distinción es crucial porque revela que la infraestructura urbana responde de manera distinta según el tipo de inundación, lo que obliga a pensar soluciones más específicas y no generalizadas.

En conjunto, la evidencia demuestra que la infraestructura urbana no es un elemento pasivo frente a las inundaciones, pues las influye, las amplifica, las condiciona y, al mismo tiempo, resulta dañada por ellas. La manera en que se diseñan se ubica y se mantienen las vías, los drenajes, las edificaciones y los equipamientos determina no sólo la magnitud del impacto, sino también la rapidez con la que una ciudad logra recuperarse. Esto es una mirada más territorial y humana del fenómeno lo que permite entender que las inundaciones no solo afectan estructuras físicas; también interrumpen la vida cotidiana, las rutinas y las conexiones esenciales que sostienen el funcionamiento urbano.

Conclusiones

El análisis de la literatura reciente muestra que las inundaciones en entornos urbanos representan uno de los problemas más desafiantes y complejos de abordar, es una discusión que presenta desafíos desde el punto de vista técnico y de gestión. Las revisiones sistemáticas confirmaron que, a pesar de la variedad de diversas metodologías, persiste la concentración de estudios en contextos específicos lo que restringe la transferencia directa de metodologías para entornos urbanos en países en desarrollo. Se identifica que la teledetección y los Sistemas de Información Geográfica, están consolidados como metodologías para la delimitación de regiones inundadas y estimar daños, pero su máximo potencial se alcanza cuando se combinan con información detallada sobre el uso del suelo, la topografía y la infraestructura urbana.

Metodológicamente, se notó un cambio importante hacia aplicaciones más complejas que aprovechan el aprendizaje automático y, sobre todo, el aprendizaje profundo a partir de índices espectrales clásicos y enfoques de clasificación supervisada. Modelos como las redes neuronales convolucionales, arquitecturas tipo U-Net y variantes más avanzadas demuestran un rendimiento muy alto en la detección de agua y segmentación de zonas de inundación, incluso en escenarios urbanos complejos. Sin embargo, su implementación sigue estando condicionada por la disponibilidad de datos de entrenamiento, el acceso a capacidades computacionales y la necesidad de una evaluación cuidadosa.

La revisión también demostró que las integraciones de métodos proporcionan resultados más sólidos de los que métodos aislados. Con el objetivo de delimitar la extensión de inundaciones e identificar qué tipo de infraestructuras están más afectadas, la forma óptima es la fusión de imágenes satelitales productos derivados de modelos digitales de elevación y capas de infraestructura urbana, aun así, este tipo de trabajos tienden a centrarse en la delimitación y estimación de daños directos, pero con pocos sustentos o estudios que vinculen los resultados con la planificación urbana, y la ordenación del territorio.

En cuanto a las limitaciones, se ha observado que muchos de estos métodos todavía están influenciados por problemas recurrentes como la nubosidad en los sensores ópticos, la falta de resolución espacial para detalles pequeños en entornos densamente construidos, los efectos de sombra y el doble rebote en los datos SAR, y la falta de series temporales largas y homogéneas. A esto se suma la limitada incorporación de información socioeconómica y de vulnerabilidad, lo que limita la capacidad de los estudios para ir más allá del aspecto puramente físico de un evento e integrar sólidamente las dimensiones sociales y territoriales del riesgo.

Por último, la revisión pide un cambio hacia enfoques holísticos que integren la teledetección, los sistemas de información geográfica (SIG), las técnicas de aprendizaje automático y los modelos hidrológicos con datos contextuales sobre infraestructura, población y gobernanza urbana. El desarrollo y la adaptación de estas metodologías en ciudades latinoamericanas, donde convergen la exposición a inundaciones, la rápida transformación del suelo y las importantes limitaciones de disponibilidad y calidad de datos, también se identifica como una oportunidad prioritaria. En general, los resultados tanto de la matriz bibliométrica como de la Tabla 2 nos permiten concluir

que existe una base metodológica sólida pero aún fragmentada que necesita ser mejor articulada para apoyar eficazmente la gestión del riesgo de inundaciones en contextos urbanos complejos.

1. Sobre los criterios de búsqueda, selección y exclusión de fuentes

La revisión de metodología aplicada hizo posible refinar un gran conjunto inicial de publicaciones y armar un portafolio bibliográfico que es consistente con el tema de este artículo: aplicaciones de teledetección y SIG en inundaciones urbanas y daños a la infraestructura. Y los criterios de inclusión y exclusión aplicados garantizaron un conjunto final acorde con el período de interés, las palabras clave seleccionadas y los temas relevantes presentes. Esto disminuyó la aleatoriedad de las fuentes seleccionadas y fomenta un enfoque en métodos recientes, especialmente aquellos que involucran sensores satelitales, análisis geoespacial y técnicas de aprendizaje automático.

Sin embargo, este mismo proceso también revela algunos compromisos metodológicos, ya que se priorizaron artículos recientes y ciertos tipos de documentos, lo que significa que no necesariamente se consideraron estudios clásicos o experiencias locales valiosas que no encajan completamente en los filtros existentes. No obstante, en general, el equilibrio es positivo: la estrategia de búsqueda permitió un portafolio manejable y representativo para responder a las preguntas de la monografía y proporcionar suficiente profundidad en la descripción de las tendencias metodológicas predominantes.

2. Sobre la identificación de metodologías para la delimitación de inundaciones y la evaluación de daños en infraestructura urbana

La matriz bibliométrica y la Tabla 2 indican que las metodologías están agrupadas en varios bloques. Por un lado, hay enfoques basados en índices espectrales y clasificación supervisada, que utilizan principalmente imágenes ópticas y representan una base sólida desde la cual delinear cuerpos de agua y áreas inundadas. Por otro lado, hay métodos que utilizan datos SAR mediante umbralización, pérdida de coherencia o detección de cambios, que son especialmente útiles en situaciones con cobertura de nubes o durante eventos de rápida evolución.

Además, se presentan los métodos de aprendizaje automático y aprendizaje profundo, que ocupan un lugar central en la producción reciente. Las redes neuronales convolucionales, las arquitecturas basadas en segmentación y los modelos híbridos de información satelital que utilizan variables topográficas e hidrológicas en conjunto, son avances clave en la precisión del mapeo y en la mecanización de tareas. También se describen métodos que conectan la teledetección con modelos hidrológicos o hidráulicos, además de datos de UAV, entre otras fuentes de alta resolución para validación o ajuste local.

El objetivo de identificar y sistematizar estas metodologías se cumple satisfactoriamente: se puede saber qué tipos de datos se utilizan con más frecuencia, qué algoritmos dominan, qué resoluciones espaciales se usan más a menudo y qué énfasis se pone en evaluar los daños a la infraestructura. La revisión demuestra que, aunque los enfoques son diversos por naturaleza todos comparten la intención de aprovechar la información geoespacial disponible para proporcionar productos útiles en contextos de emergencia y planificación.

Basado en la identificación y sistematización de metodologías, los patrones técnicos más fuertes que se repitieron en la literatura se hicieron evidentes. Los estudios revisados emplean principalmente sensores satelitales de resolución media (particularmente Sentinel-1 (10–20 m) para análisis SAR y Sentinel-2 (10 m) para datos ópticos), complementados en algunos casos con imágenes de muy alta resolución como PlanetScope (3 m), SkySat o fotografías de UAV (10–30 cm) cuando se requiere un detalle superior en áreas urbanas. Con respecto a los algoritmos, las arquitecturas de aprendizaje profundo (como U-Net, FCN-ResNet50, BASNet, DeepLab v3) y los métodos de aprendizaje automático (Random Forest, SVM), junto con clasificadores basados en umbrales SAR, han prevalecido en gran medida. Estas técnicas se emplean tanto para la delimitación del agua como para el análisis de cambios o detección de daños. Las resoluciones espaciales que son más comunes en la práctica (10 m y 20 m) para sensores satelitales y < 1 m para UAV, indican que los datos globales deben equilibrarse con la necesidad de detalle en ciudades densas. La revisión demuestra que, aunque los diversos enfoques se originaron en diferentes contextos, todos apuntan a mejorar la aplicación de información geoespacial de múltiples fuentes para obtener mapas confiables utilizados en emergencias y actividades de planificación urbana.

3. Sobre el análisis de tendencias, limitaciones y alcances de las metodologías identificadas

La evaluación comparativa nos permite afirmar que hay una tendencia significativa hacia la combinación de múltiples fuentes de datos y el uso de métodos más complejos. Sin embargo, esta complejidad no necesariamente se puede transferir fácilmente a entornos donde hay datos limitados y facilidades técnicas limitadas. La mayoría de los enfoques discutidos hasta ahora se han probado en ciudades con abundantes datos, soluciones tecnológicas maduras y redes de observación relativamente densas, lo que genera incertidumbre sobre su aplicabilidad en áreas con menor capacidad institucional.

En cuanto a las limitaciones, se reiteran los desafíos de capturar inundaciones superficiales y de corta duración, la dependencia de datos de entrenamiento de calidad, así como el costo computacional de algunos modelos, mientras que hay una falta de incorporación de datos sobre vulnerabilidad social y criticidad de la infraestructura.

No obstante, las metodologías revisadas presentan un importante portafolio de contribuciones. Han permitido un mejor mapeo de las áreas de inundación, acelerado el mapeo de daños, explorando escenarios de fusión de sensores y avanzado en el desarrollo de esquemas de monitoreo y alerta más dinámicos. La oportunidad clave identificada aquí es utilizar estos principios técnicos fundamentales para desarrollar sistemas más robustos, combinando el potencial de los modelos basados en datos con el conocimiento local, la información de infraestructura crítica y las necesidades reales de la gestión del territorio. Como resultado, las metodologías no solo describirían de manera más concreta lo que ocurre durante una inundación, sino que también avanzaría en la dirección de decisiones preventivas y la transformación urbana a mediano y largo plazo.

Referencias

- Abuhani, D. A., Aldamani, R., Zualkernan, I., Alali, R., & Grover, H. (2025). Floods' Impact on Cities' Critical Infrastructure: A Case Study on Dubai. *IEEE Access*, 13, 17652–17661. <https://doi.org/10.1109/ACCESS.2025.3527554>
- Afonso, M. H. F., Souza, J. V. de, Ensslin, S. R., & Ensslin, L. (2012). Como construir conhecimento sobre o tema de pesquisa? Aplicação do processo proknow-c na busca de literatura sobre avaliação do desenvolvimento sustentável. *Revista de Gestão Social e Ambiental*, 5(2), 47–62. <https://doi.org/10.24857/rgsa.v5i2.424>
- Akinsoji, A. H., Adelodun, B., Adeyi, Q., Salau, R. A., Odey, G., & Choi, K. S. (2024). Integrating machine learning models with comprehensive data strategies and optimization techniques to enhance flood prediction accuracy: a review. *Water Resources Management*, 38(12), 4735–4761.
- Albertini, C., Gioia, A., Iacobellis, V., & Manfreda, S. (2022). Detection of surface water and floods with multispectral satellites. *Remote Sensing*, 14(23), 6005.
- Alex Immanuel Jeyasingh, R., Patricia Kalai Arasi, J., Susan Poonguzhali, R., & Suguna Devakumari, M. (2024). A Geospatial assessment of Flood Susceptibility in Viluppuram Region of Tamil Nadu. *Water and Energy International*, 67r(1), 6–11. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85205026486&partnerID=40&md5=3e0e6786c7e76ed29f709ec6d709e98e>
- Amitrano, D., Di Martino, G., Di Simone, A., & Imperatore, P. (2024). Flood Detection with SAR: A Review of Techniques and Datasets. *Remote Sensing*, 16(4). <https://doi.org/10.3390/rs16040656>
- An, T. T., Izuru, S., Narumasa, T., Raghavan, V., Hanh, L. N., An, N. V., Long, N. V., Thuy, N. T., & Minh, T. P. (2022). Flood vulnerability assessment at the local scale using remote sensing and GIS techniques: a case study in Da Nang City, Vietnam. *Journal of Water and Climate Change*, 13(9), 3217–3238. <https://doi.org/10.2166/wcc.2022.029>
- Anik, M. S. B. M., An, C., & Li, S. S. (2025). Evolution from the physical process-based approaches to machine learning approaches to predicting urban floods: a literature review. *Environmental Systems Research*, 14(1). <https://doi.org/10.1186/S40068-025-00409-3>
- Arias Choquehuanca, D. A., Campos Neciosup, B. I., & Quiroz Jiménez, K. (2023). Flooding mapping detection and urban affectation using Google Earth Engine. *DYNA: Revista de La Facultad de Minas. Universidad Nacional de Colombia. Sede Medellín*, 90(229), 129–136. <https://dialnet.unirioja.es/servlet/extart?codigo=9246248>
- Baghermanesh, S. S., Jabari, S., & McGrath, H. (2022). Urban Flood Detection Using TerraSAR-X and SAR Simulated Reflectivity Maps. *Remote Sensing*, 14(23). <https://doi.org/10.3390/rs14236154>
- Bai, Y., Wu, W., Yang, Z., Yu, J., Zhao, B., Liu, X., Yang, H., Mas, E., & Koshimura, S. (2021). Enhancement of detecting permanent water and temporary water in flood disasters by fusing sentinel-1 and sentinel-2 imagery using deep learning algorithms: Demonstration of

- p1floods11 benchmark datasets.
- Remote Sensing*
- , 13(11).
-
- <https://doi.org/10.3390/rs13112220>
-
- Batmanathan, N. M., Pereira, J. J., Shah, A. A., Muhamad, N., & Lim, L. C. (2025). Land Subsidence and Coastal Flood Impact Scenarios Based on Remote Sensing in Selangor, Malaysia.
- Journal of Marine Science and Engineering*
- , 13(8).
-
- <https://doi.org/10.3390/jmse13081539>
-
- Belenguer-Plomer, M. A., Barrilero, O., Saameño, P., Mendes, I., Lazzarini, M., Albani, S., El Beyrouthy, N., Al Sayah, M., Rueche, N., & Edjossan-Sossou, A. M. (2025). Remote Sensing as a Sentinel for Safeguarding European Critical Infrastructure in the Face of Natural Disasters.
- Applied Sciences (Switzerland)*
- , 15(16).
- <https://doi.org/10.3390/app15168908>
-
- Bentivoglio, R., Isufi, E., Jonkman, S. N., & Taormina, R. (2021). Deep learning methods for flood mapping: A review of existing applications and future research directions.
- Hydrology and Earth System Sciences Discussions*
- , 2021, 1–43.
-
- Bolick, M. M., Post, C. J., Naser, M. Z., Forghanparast, F., & Mikhailova, E. A. (2023). Evaluating Urban Stream Flooding with Machine Learning, LiDAR, and 3D Modeling.
- Water (Switzerland)*
- , 15(14).
- <https://doi.org/10.3390/w15142581>
-
- Bolzán, R., & Mendes Filho, L. (2022). Construcción de conocimiento sobre la experiencia turística: una revisión sistematizada de la literatura a partir del método Proknow-C.
- Turismo-Visão e Ação*
- , 24, 430–448.
- <https://doi.org/10.14210/rtva.v24n3p430-448>
-
- Bonafilia, D., Tellman, B., Anderson, T., & Issenberg, E. (2020).
- Sen1Floods11: a georeferenced dataset to train and test deep learning flood algorithms for Sentinel-1*
- .
- www.cloudtostreet.info
-
- Cerbelaud, A., Blanchet, G., Roupioz, L., Breil, P., & Briottet, X. (2023). Mapping Pluvial Flood-Induced Damages with Multi-Sensor Optical Remote Sensing: A Transferable Approach.
- Remote Sensing*
- , 15(9).
- <https://doi.org/10.3390/rs15092361>
-
- Chitwatkulsiri, D., & Miyamoto, H. (2023). Real-time urban flood forecasting systems for southeast asia—a review of present modelling and its future prospects.
- Water*
- , 15(1), 178.
-
- Da Silva, C. J., López, P. E., & Arias, F. C. (2022). Las inundaciones en las áreas urbanas: El caso del Área Metropolitana del Gran Resistencia.
- Revista de Geografía Norte Grande*
- , 82, 333–354.
- <https://dialnet.unirioja.es/servlet/extart?codigo=8690250>
-
- Gokon, H., Endo, F., & Koshimura, S. (2023). Detecting Urban Floods with Small and Large Scale Analysis of ALOS-2/PALSAR-2 Data.
- Remote Sensing*
- , 15(2).
-
- <https://doi.org/10.3390/rs15020532>
-
- Gosset, M., Dibi-Anoh, P. A., Schumann, G., Hostache, R., Paris, A., Zahiri, E. P., Kacou, M., & Gal, L. (2023). Hydrometeorological Extreme Events in Africa: The Role of Satellite Observations for Monitoring Pluvial and Fluvial Flood Risk.
- Surveys in Geophysics*
- , 44(1), 197–223.
- <https://doi.org/10.1007/S10712-022-09749-6>
-
- Goyal, H. R., Ghanshala, K. K., & Sharma, S. (2021). Post flood management system based on smart IoT devices using AI approach.
- Materials Today: Proceedings*
- , 46, 10411–10417.
- <https://doi.org/10.1016/j.matpr.2020.12.947>
-
- Ha, M. C., Vu, P. L., Nguyen, H. D., Hoang, T. P., Dang, D. D., Dinh, T. B. H., Şerban, G., Rus, I., & Breţcan, P. (2022). Machine Learning and Remote Sensing Application for Extreme Climate Evaluation: Example of Flood Susceptibility in the Hue Province, Central Vietnam Region.
- Water (Switzerland)*
- , 14(10).
- <https://doi.org/10.3390/w14101617>
-
- Hamidi, E., Peter, B. G., Muñoz, D. F., Moftakhari, H., & Moradkhani, H. (2023). Fast Flood Extent Monitoring With SAR Change Detection Using Google Earth Engine.
- IEEE*

- Transactions on Geoscience and Remote Sensing*, 61.
<https://doi.org/10.1109/TGRS.2023.3240097>
- Hlal, M., Baraka Munyaka, J.-C., Chenal, J., Azmi, R., Diop, E. B., Bounabi, M., Ebnou Abdem, S. A., Almouctar, M. A. S., & Adraoui, M. (2025). Digital Twin Technology for Urban Flood Risk Management: A Systematic Review of Remote Sensing Applications and Early Warning Systems. *Remote Sensing*, 17(17), 3104.
- Iqbal, U., Riaz, M. Z. Bin, Zhao, J., Barthelemy, J., & Perez, P. (2023). Drones for flood monitoring, mapping and detection: A bibliometric review. *Drones*, 7(1), 32.
- Islam, T., Zeleke, E. B., Afroz, M., & Melesse, A. M. (2025). A Systematic Review of Urban Flood Susceptibility Mapping: Remote Sensing, Machine Learning, and Other Modeling Approaches. *Remote Sensing*, 17(3), 524.
- Jackowski, K., Burduk, R., Walkowiak, K., Wozniak, M., & Yin, H. (Eds.). (2015). *A Distributed Approach to Flood Prediction Using a WSN and ML: A Comparative Study of ML Techniques in a WSN Deployed in Brazil* (Vol. 9375). Springer International Publishing.
<https://doi.org/10.1007/978-3-319-24834-9>
- Koko, A., Wu, W., Abdullahi Abubakar, G., Hamed, R., & Alabsi, A. A. (2021). Analyzing urban growth and land cover change scenario in Lagos, Nigeria using multi-temporal remote sensing data and GIS to mitigate flooding. *Geomatics, Natural Hazards and Risk*, 12(1), 631–652.
<https://doi.org/10.1080/19475705.2021.1887940>
- Kulk, G., Sathyendranath, S., Platt, T., Grinson-George, G., Suresan, A. K., Menon, N., Evers-King, H., & Abdulaziz, A. (2023). Using Multi-Spectral Remote Sensing for Flood Mapping: A Case Study in Lake Vembanad, India. *Remote Sensing*, 15(21).
<https://doi.org/10.3390/rs15215139>
- Kumari, S., Agarwal, S., Agrawal, N. K., Agarwal, A., & Garg, M. C. (2025). A comprehensive review of remote sensing technologies for improved geological disaster management. *Geological Journal*, 60(1), 223–235.
- Li, L., Woodley, A., & Chappell, T. (2024). Mapping Urban Floods via Spectral Indices and Machine Learning Algorithms. *Sustainability (Switzerland)*, 16(6).
<https://doi.org/10.3390/su16062493>
- Liu, B., Li, Y., Ma, M., & Mao, B. (2025). A Comprehensive Review of Machine Learning Approaches for Flood Depth Estimation: Liu et al. Machine Learning Approaches for Flood Depth Estimation. *International Journal of Disaster Risk Science*, 1–13.
- Malinverni, E. S., Di Stefano, F., Chiappini, S., Darvini, G., Fronzi, D., Pierdicca, R., & Tazioli, A. (2025). LiDAR-driven Topographic Surveys for Floodplain Management. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 48(G-2025), 1035–1042. <https://doi.org/10.5194/isprs-archives-XLVIII-G-2025-1035-2025>
- Mason, D. C., Bevington, J., Dance, S. L., Revilla-Romero, B., Smith, R., Vetra-Carvalho, S., & Cloke, H. L. (2021). Improving urban flood mapping by merging synthetic aperture radar-derived flood footprints with flood hazard maps. *Water (Switzerland)*, 13(11).
<https://doi.org/10.3390/w13111577>
- Mohamadiazar, N., Ebrahimian, A., & Hosseiny, H. (2024). Integrating deep learning, satellite image processing, and spatial-temporal analysis for urban flood prediction. *Journal of Hydrology*, 639. <https://doi.org/10.1016/j.jhydrol.2024.131508>
- Narin, O. G., Sekertekin, A., Bayik, C., Bektas Balcik, F., Arıkan, M., Balik Sanli, F. B., & Abdikan, S. (2025). Multi-Sensor Flood Mapping in Urban and Agricultural Landscapes of

- the Netherlands Using SAR and Optical Data with Random Forest Classifier. *Remote Sensing*, 17(15). <https://doi.org/10.3390/rs17152712>
- Osco, L. P., Marcato Junior, J., Marques Ramos, A. P., de Castro Jorge, L. A., Fatholahi, S. N., de Andrade Silva, J., Matsubara, E. T., Pistori, H., Gonçalves, W. N., & Li, J. (2021). A review on deep learning in UAV remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102456. <https://doi.org/10.1016/j.jag.2021.102456>
- Pelich, R., Chini, M., Hostache, R., Matgen, P., Pulvirenti, L., & Pierdicca, N. (2022). Mapping Floods in Urban Areas from Dual-Polarization InSAR Coherence Data. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2021.3110132>
- Roohi, M., Dehghani, J., Irani, M., & Mina, P. (2025). A comprehensive review of flood damage in mountainous regions: challenges, solutions, and advanced management technologies. *Discover Geoscience*, 3(1). <https://doi.org/10.1007/S44288-025-00145-2>
- Roohi, M., Ghafouri, H. R., Ashrafi, S. M., Motagh, M., & Haghshenas Haghighi, M. (2025). A hybrid approach for enhanced flood prediction and assessment: Leveraging physical models, deep learning and satellite remote sensing. *Big Earth Data*. <https://doi.org/10.1080/20964471.2025.2530850>
- Sajjad, A., Ahmad, M., Aslam, R. W., Bibi, M., & Tabassum, A. (2025). Remote sensing-based flash flood mapping and damage assessment in Dera Ismail Khan, Khyber Pakhtunkhwa, Pakistan. *Environmental Monitoring and Assessment*, 197(4). <https://doi.org/10.1007/s10661-025-13894-x>
- Sathees Babu, S., Sonia, J. J., Aarthee, S., Chithambaramani, R., & Ganeshkumar, P. (2025). A Hybrid Deep Learning Approach for Flood Prediction: Integrating ICENet's Spatial-Temporal Learning with DRAW Optimizer's Adaptive Weighting. *Water Resources Management*. <https://doi.org/10.1007/S11269-025-04330-3>
- Schumann, G., Giustarini, L., Tarpanelli, A., Jarihani, B., & Martinis, S. (2023). Flood Modeling and Prediction Using Earth Observation Data. *Surveys in Geophysics*, 44(5), 1553–1578. <https://doi.org/10.1007/S10712-022-09751-Y>
- Souza, I. A., & de Amorim Silva, V. (2025). Flood Prediction in Brazil: A Review of Trends, Gaps and Methodological Perspectives. *Journal of South American Earth Sciences*, 105637.
- Tanim, A. H., McRae, C. B., Tavakol-Davani, H., & Goharian, E. (2022). Flood Detection in Urban Areas Using Satellite Imagery and Machine Learning. *Water (Switzerland)*, 14(7). <https://doi.org/10.3390/w14071140>
- Van, L. N., Nguyen, G. V., Kim, Y., Do, M. T. T., Kwon, S., Lee, J., & Lee, G. (2025). Rapid Urban Flood Detection Using PlanetScope Imagery and Thresholding Methods. *Water (Switzerland)*, 17(7). <https://doi.org/10.3390/w17071005>
- Waseem, H. Bin, & Rana, I. A. (2023). Floods in Pakistan: A state-of-the-art review. *Natural Hazards Research*, 3(3), 359–373. <https://doi.org/10.1016/j.nhres.2023.06.005>
- Wu, Z., Zheng, X., Chen, Y., Huang, S., Hu, W., & Duan, C. (2023). Urban Flood Loss Assessment and Index Insurance Compensation Estimation by Integrating Remote Sensing and Rainfall Multi-Source Data: A Case Study of the 2021 Henan Rainstorm. *Sustainability (Switzerland)*, 15(15). <https://doi.org/10.3390/su151511639>
- Yan, Y., Zhang, N., & Zhang, H. (2023). Applications of advanced technologies in the development of urban flood models. *Water*, 15(4), 622.
- Zhang, H., Qi, Z., Li, X., Chen, Y., Wang, X., & He, Y. (2021). An urban flooding index for unsupervised inundated urban area detection using sentinel-1 polarimetric SAR images. *Remote Sensing*, 13(22). <https://doi.org/10.3390/rs13224511>

-
- Zhang, M., Chen, Z., Wang, J., Kar, B., Pierce, M., Tiampo, K., Eguchi, R., & Glasscoe, M. (2025). Optical Remote Sensing for Global Flood Disaster Mapping: A Critical Review Towards Operational Readiness. *Remote Sensing*, 17(11), 1886.
- Zhao, J., Li, M., Li, Y., Matgen, P., & Chini, M. (2025). Urban Flood Mapping Using Satellite Synthetic Aperture Radar Data: A review of characteristics, approaches, and datasets. *IEEE Geoscience and Remote Sensing Magazine*, 13(1), 237–268. <https://doi.org/10.1109/MGRS.2024.3496075>
- Zhao, J., Li, Y., Matgen, P., Pelich, R., Hostache, R., Wagner, W., & Chini, M. (2022). Urban-Aware U-Net for Large-Scale Urban Flood Mapping Using Multitemporal Sentinel-1 Intensity and Interferometric Coherence. *IEEE Transactions on Geoscience and Remote Sensing*, 60. <https://doi.org/10.1109/TGRS.2022.3199036>
- Zhran, M., Ghanem, K., Tariq, A., Alshehri, F., Jin, S., Das, J., Pande, C. B., Pramanik, M., Hasher, F. F. B., & Mousa, A. (2024). Exploring a GIS-based analytic hierarchy process for spatial flood risk assessment in Egypt: a case study of the Damietta branch. *Environmental Sciences Europe*, 36(1). <https://doi.org/10.1186/s12302-024-01001-9>
- Zhu, Y., Yoshimura, K., Liu, Y., & Fu, H. (2025). Global flood extent monitoring using SAR satellite and hydrological data: A multi-scale and multi-source approach. *Journal of Hydrology*, 663, 134074. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2025.134074>