

4

ARTICULO DE REVISIÓN

REDES NEURONALES CONVOLUCIONALES (RNC), PARA IDENTIFICAR Y CLASIFICAR DAÑOS EN MATERIALES ESTRUCTURALES A PARTIR DE IMÁGENES FOTOGRÁFICAS

Fecha de recepción: 11/08 /2026 | Fecha de aceptación: 15/05/2026

Autor(es):

¹ Gonzales Soto Ronald Fernando,

¹ Docente asignatura de métodos y técnicas de investigación (UNIPOL), Candidato a Doctor, Universidad Autónoma Juan Misael Saracho (UAJMS)



Redes Neuronales Convolucionales (RNC), para identificar y clasificar daños en materiales estructurales a partir de imágenes fotográficas

1. INTRODUCCIÓN

La seguridad y durabilidad de las infraestructuras civiles se ven constantemente amenazadas por el deterioro natural del hormigón armado, que se manifiesta en forma de desprendimientos y armaduras expuestas. El mantenimiento de estas estructuras no solo es una cuestión de seguridad pública, sino también un enorme reto económico, especialmente si se tiene en cuenta que gran parte de las infraestructuras críticas se construyeron hace varios años y requieren inspecciones cada vez más frecuentes.

Tradicionalmente, la identificación de patologías como grietas y fisuras se ha basado en inspecciones visuales manuales realizadas por profesionales ingenieros. Sin embargo, este enfoque convencional tiene limitaciones como ser extremadamente laborioso, costoso, lento y, sobre todo, está sujeto al criterio humano de los especialistas, lo que compromete la fiabilidad de los registros históricos. Además, estas tareas a menudo exponen a los especialistas a riesgos físicos en zonas de difícil acceso o en estructuras deterioradas.

Para superar estas deficiencias, investigaciones recientes proponen una transición hacia sistemas automatizados basados en la visión artificial y el aprendizaje profundo. El uso de redes neuronales convolucionales (RNC) permite automatizar el aprendizaje de características

complejas directamente a partir de imágenes, lo que elimina la necesidad de un preprocesamiento manual y ofrece una alternativa más objetiva para la monitorización del estado estructural. Según Shi y otros (2025) ha propuesto un modelo RNC que optimiza mediante el ajuste de hiperparámetros como el tamaño del núcleo y el uso de técnicas de regularización como el dropout para predecir diversos tipos de daños en el hormigón. Otros autores han implementado otras variantes modificadas de AlexNet, logrando precisiones superiores al 99 % mediante el entrenamiento con bases de datos de hasta 60 000 imágenes (Li & Zhao, 2019)

La segmentación semántica es otro avance clave, ya que permite identificar los daños a nivel de píxel. La investigación ha desarrollado redes totalmente convolucionales que utilizan Resnet-18 como codificador e integran convoluciones dilatadas para capturar detalles finos sin perder información semántica compleja. Estos modelos han demostrado su superioridad sobre arquitecturas convencionales como VGG y Resnet-50, alcanzando una precisión de píxeles mayor al 96 % (Zhang y otros, 2019). El aprendizaje por transferencia se ha convertido en una estrategia eficaz para entrenar modelos robustos con menos recursos. Según Leal da Silva & Schwerz de Lucena, (2018) que concuerda lo que indica Savino & Tondolo (2021) han utilizado arquitecturas preentrenadas, como VGG16 y GoogLeNet, para clasi-

Palabras Claves: Seguridad de activos tecnológicos, inventario TI, modelo de seguridad TI.

Keywords: Technological asset security, IT inventory, IT security model

ficar defectos en diversas condiciones de luz y textura, logrando precisiones de validación de hasta el 94 % en la detección de grietas y delaminaciones en puentes y túneles.

En el ámbito de la inspección de edificios urbanos de gran altura, Hoang (2019) han propuesto métodos que integran técnicas de aprendizaje automático, como las máquinas de vectores de soporte (SVM), para clasificar los daños en etiquetas específicas, como grietas longitudinales, transversales o diagonales. Estos enfoques buscan optimizar los trabajos de mantenimiento y reducir significativamente los costes operativos de las agencias de inspección. Para abordar problemas específicos, como el desequilibrio de datos (como la profundidad de la grieta), se ha introducido el modelo CrackGAN. Esta red generativa adversaria utiliza una arquitectura U-Net asimétrica para identificar defectos incluso cuando los límites son vagos o las grietas son frágiles, superando a los métodos de segmentación convencionales en entornos industriales reales (Zhang y otros, 2020).

La innovación también se extiende a la implementación práctica a través de dispositivos portátiles y drones. Se han desarrollado flujos de trabajo que permiten realizar diagnósticos en tiempo real desde teléfonos inteligentes o vehículos aéreos no tripulados, lo que facilita las inspecciones remotas en sitios peligrosos o de alturas considerables. Esto no solo garantiza la seguridad del personal, sino que también permite una gestión más eficiente de los registros de mantenimiento a largo plazo (Kim y otros, 2019). Por último, los últimos modelos se basan en técnicas de aprendizaje conjunto e interpretabilidad, como Grad-CAM. Al combinar múltiples submodelos (como AlexNet, Xception o ResNet50), los diferentes autores como Sadegh Barkhordari y otros (2022) también Shamila y otros (2021) y Pereira Junior y otros (2024) exponen que se han alcanzado niveles de precisión de mayores al 99 %, lo que garantiza que

la inteligencia artificial se centre correctamente en las características físicas de las grietas y proporciona herramientas de alta fidelidad para la ingeniería estructural moderna.

2. MÉTODO

La revisión sistemática es el método ideal para un artículo de revisión que analiza, sistematiza e integra los resultados de investigaciones publicadas, lo que permite identificar avances y tendencias de manera rigurosa y reproducible. Este enfoque se adapta perfectamente al campo de la ingeniería estructural, en consonancia con su experiencia en el análisis de documentos.

Se definieron los criterios de inclusión (artículos publicados entre 2018 y 2025 en revistas indexadas por Scopus o IEEE, centrados en la visión artificial aplicada a la ingeniería estructural) y los criterios de exclusión (estudios no empíricos o estudios sin datos de imágenes reales). A continuación, se realizaron búsquedas exhaustivas en bases de datos como Google Scholar, IEEE Xplore y Scopus utilizando términos como «CNN structural damage detection images» (imágenes de detección de daños estructurales con CNN) O «convolutional neural networks material damage» (redes neuronales convolucionales daños materiales).

3. DESARROLLO DEL TEMA

3.1. Recopilación y preparación de datos

La fase de datos es la piedra angular para lograr capacidades efectivas de aprendizaje y generalización en los modelos de redes neuronales convolucionales (RNC).

Adquisición de imágenes: se utilizaron cámaras digitales y teléfonos inteligentes para capturar imágenes de alta resolución a distancias de entre 0,5 y 3 metros, lo que permitió documentar las patologías en condiciones reales de campo.

Figura 1. Recopilación de datos



Estandarización y formato: las imágenes se recortaron y redimensionaron a formatos estándar, como 224×224 o 227×227 píxeles, para que fueran compatibles con las capas de entrada de las redes.

Figura 2. Preparación de datos




Técnicas de aumento de datos: Con el fin de evitar el sobreajuste y mejorar la robustez frente a las variaciones ambientales, se aplicaron rotaciones, reflejos y ajustes de brillo, logrando precisiones cercanas al 96 % en modelos como ResNet50. Conjuntos de datos y etiquetado: Se utilizaron bases de datos masivas, que iban desde 4585 imágenes para la clasificación de fallas sísmicas hasta 60 000 imágenes para modelos basados en Alex-

Net, a menudo validadas por ingenieros especialistas.

3.2. Desarrollo del modelo y arquitectura

La investigación propone el uso de arquitecturas de aprendizaje profundo para reconocer patrones y jerarquías espaciales en imágenes digitales de hormigón. Aprendizaje por transferencia: se utilizaron modelos preentrenados como VGG16, VGG19 y GoogLeNet, lo que permitió una alta capacidad de abstracción incluso con recursos computacionales limitados. Redes residuales (ResNets): se implementaron arquitecturas como ResNet-18 y ResNet50, que utilizan conexiones directas para permitir el entrenamiento de hasta 152 capas sin degradación de la precisión.

Figura 3. Desarrollo y entrenamiento del modelo



Modelos de segmentación semántica: se desarrollaron arquitecturas de redes totalmente convolucionales (FCN) y U-Net para la identificación de daños a nivel de píxeles, integrando convoluciones dilatadas para ampliar el campo receptivo sin perder detalles finos. Aprendizaje conjunto: se diseñaron marcos que combinan múltiples submodelos (como AlexNet y Xception) utilizando técnicas de apilamiento o promedio ponderado, superando a los modelos individuales.

3.3. Proceso de formación y evaluación

La formación se diseñó para maximizar la convergencia y la capacidad de diagnóstico de los sistemas:

Configuración de la formación: Se utilizó principalmente el optimizador ADAM por su tasa de aprendizaje adaptativa, junto con funciones de pérdida como la entropía cruzada categórica. Se utilizaron funciones de activación ReLU en las capas internas y Softmax en la capa de salida para generar probabilidades de clase.

Hiperparámetros y plataformas: Las tasas de aprendizaje se fijaron en 0,001 y se utilizaron plataformas como TensorFlow, Keras y Teachable Machine. La supervisión de la pérdida de validación permitió un ajuste dinámico del proceso para evitar el estancamiento.

Métricas de evaluación: El rendimiento se validó utilizando la precisión de píxeles (PA), que alcanzó el 96,84 % en los modelos de segmentación, y la intersección media sobre la unión (MIoU). Otros modelos de clasificación binaria («fisurado» frente a «no fisurado») alcanzaron precisiones excepcionales de hasta el 99,78 %.

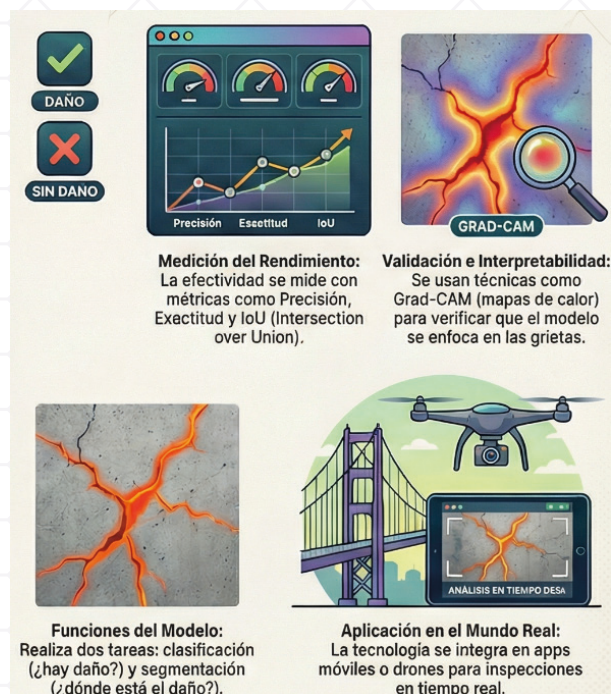
Interpretabilidad: Se integró la técnica Gradient Activation Mapping (Grad-CAM) para visualizar las áreas de la imagen que desencadenaron la predicción, lo que garantizó que la red detectara las características físicas reales de la patología y no el ruido ambiental.

Se ha desarrollado el modelo RNC, una arquitectura de tres capas que ha logrado una precisión del 98,81 % en la detección de daños complejos, superando a modelos como ResNet50 y VGG16 en tareas específicas (Shi y otros, 2025). Según Lung Fan (2024) las nuevas tendencias han avanzado hacia sistemas híbridos que combinan la clasificación con la segmentación semántica a través de redes totalmente convolucionales (RTC). Este enfoque permite no solo identificar, sino también delimitar daños como el refuerzo expuesto y el desprendimiento, logrando precisiones de clasificación del 98,75 % y precisiones de segmentación del 95,98 % utilizando imágenes capturadas con teléfonos inteligentes.

Por otro lado, la integración de modelos en aplicaciones móviles ha sido impulsada por arquitecturas basadas en AlexNet. Estos sistemas utilizan técnicas exhaustivas de búsqueda con ventana deslizante para la detección automática de grietas en tiempo real (Li & Zhao, 2019). Del mismo modo, para la segmentación a nivel de píxeles, se ha propuesto el uso de Resnet-18 como codificador dentro de una estructura RTC, empleando convoluciones dilatadas para capturar detalles finos con una precisión del 96,84 % (Zhang y otros, 2019).

El concepto de aprendizaje por transferencia es un pilar recurrente que permite que modelos como VGG16, preentrenados con grandes bases de datos, se adapten con éxito para clasificar daños en condiciones variables de luz y textura (Leal da Silva & Schwerz de Lucena, 2018). Además, se han perfeccionado los flujos de trabajo que dividen las imágenes en «unidades de parche» y aplican algoritmos de adelgazamiento para cuantificar numéricamente la anchura y la longitud de las grietas (Kim y otros, 2019).

Figura 4. Evaluación y aplicación



Para la detección de patologías en fachadas de difícil acceso, como moho y manchas, el uso de VGG-16 junto con la técnica CAM (Class Activation Map) ha permitido localizar defectos sin necesidad de etiquetas de ubicación precisas, lo que facilita el uso de drones (Perez y otros, 2019). Del mismo modo, se han diseñado CNN específicas para clasificar los daños causados por los terremotos en edificios de hormigón armado, lo que proporciona herramientas rápidas para las evaluaciones de seguridad tras los desastres (Gomera & Ballim, 2022).

La investigación también aborda el mantenimiento del pavimento utilizando el modelo CrackGAN, una red generativa adversaria que resuelve el problema del desequilibrio de datos (donde el fondo eclipsa la grieta), lo que permite una detección robusta incluso con etiquetas parcialmente precisas (Zhang y otros, 2020). Estas innovaciones se basan en modelos de detección de objetos como YOLO, que se han adaptado para identificar diversos tipos de grietas en entornos industriales (Hoang, 2019).

Un avance fundamental en la arquitectura de estas redes es el aprendizaje residual que reformula las capas para aprender funciones residuales en lugar de funciones sin referencia, redes como ResNet se han entrenado con profundidades de hasta 152 capas sin pérdida de precisión (He y otros, 2018). En la infraestructura vial, la arquitectura GoogLeNet ha destacado por su eficiencia, alcanzando precisiones de validación del 94 % al eliminar la necesidad de la extracción manual de características (Savino & Tondolo, 2021).

El uso de modelos de aprendizaje conjunto representa la vanguardia actual en cuanto a rendimiento estos

combinan submodelos como MobileNetV2 y NAS-NetMobile mediante la optimización de la evolución diferencial (WAE-DE), es posible superar significativamente la precisión de cualquier modelo individual, alcanzando una precisión del 87,1 % en problemas complejos de múltiples clases (Sadegh Barkhordari y otros, 2022; Shamila y otros, 2021).

Estos avances se complementan con estudios que utilizan modelos basados en ResNet50 para clasificar patologías en edificios universitarios, logrando una precisión del 96 % tras un riguroso proceso de validación por parte de ingenieros expertos (Werle Tozevich y otros, 2024).

Por último, el desarrollo culmina con el uso de Grad-CAM para garantizar la interpretabilidad. Los estudios que comparan VGG16, VGG19 y ResNet50 han logrado precisiones casi perfectas (hasta el 99,83 %), lo que confirma que las redes se centran en las características físicas reales de las grietas y no en el ruido visual, consolidando así herramientas altamente fiables para la inspección automatizada (Pereira Junior y otros, 2024).

4. DISCUSIÓN

Como resultado del análisis exhaustivo presentado en los apartados precedentes, se ha procedido a sistematizar la información de las fuentes consultadas. En la Tabla 1 se detalla la síntesis de dichos documentos, identificando la arquitectura de las redes neuronales usadas, la presión de los hallazgos y el tamaño usado y el tamaño de imágenes para el entrenamiento del modelo, se extrajeron las fuentes más importantes y su referencia en el presente estudio.

Tabla 1. Resumen de los principales hallazgos según los autores

N°	AUTOR(ES) Y AÑO	ARQUITECTURA PRINCIPAL	PRECISIÓN REPORTADA	TAMAÑO
1	Shi et al. (2025)	CNND (3 capas conv., kernel 4x4, dropout 0.5)	98.81%	3200 imágenes
2	Lung Fan (2024)	CNN + FCN (HSV)	98.75% clasificación; 95.98% segmentación	2000 imágenes
3	Li & Zhao (2019)	AlexNet modificada	99.06%	60,000 imágenes
4	Zhang et al. (2019)	FCN-ResNet18 (dilatadas)	96.84% PA; 86.05% mIoU	600 imágenes
5	Leal da Silva Schwerz de Lucena (2018)	VGG16 (transfer learning)	92.27%	3500 imágenes
6	Kim et al. (2019)	CNN clasificación + HiRes3DNet segmentación	99.98% clasificación; IoU 0.87	40,000 (clasif.); 2000 (seg.)
7	Pérez et al. (2019)	VGG-16 + CAM	98.86%	2622 imágenes
8	Hoang (2019)	Steerable filters + LSSVM	85.33%	500 imágenes
9	Zhang et al. (2020)	CrackGAN (U-Net asimétrico)	Alta precisión (no numérica específica); superior a U-Net	No especificado (parches)
10	He et al. (2018)	ResNet (152 capas, residual)	Top en ILSVRC/COCO (base)	ImageNet (millones)
11	Savino Tondolo (2021)	GoogLeNet (transfer)	94.44%	1352 imágenes
12	САВИЦЬКИЙ et al. (2023)	TensorFlow CNN personalizada	97%	S D N E T 2 0 1 8 (1086 imágenes)
13	Bai et al. (2020)	ResNet + U-Net cascada	96.48% píxel; 93.8% escenas	Phi-Net (no num.)
14	Sadegh Barkhordari et al. (2022)	Ensemble (MobileNetV2/NASNet + WAE-DE/SSM-SVM)	94%	4585 imágenes
15	Gomera Ballim (2022)	VGG (desde cero) + Otsu	99.6%	3000 imágenes
16	Werle Tozevich et al. (2024)	ResNet50 (transfer)	96%	2040 imágenes
17	Shamila et al. (2021)	Ensemble (Custom CNN + AlexNet + Xception)	87.1%	1176 imágenes
18	Pereira Junior et al. (2024)	VGG19/ResNet50 (fine-tuning)	99.78% (VGG19); 99.83% (ResNet50)	40,000 imágenes

El análisis de la tabla comparativa muestra una notable evolución en la aplicación de las redes neuronales convolucionales (RNC) para la detección de patologías estructurales. Las arquitecturas han pasado de los modelos de clasificación convencionales, como AlexNet y VGG16, a sistemas de segmentación semántica más avanzados, como FCN-ResNet y CrackGAN. Mientras que los enfoques de clasificación pura alcanzan precisiones excepcionales (por ejemplo, el 99,06 % presentado por Li y Zhao, 2019), los modelos de segmentación

(Lung Fan, 2024; Zhang et al., 2019) aportan un valor fundamental al delinear la geometría del daño a nivel de píxeles. Esta progresión es esencial en la ingeniería civil, ya que no solo identifica la presencia de grietas, sino que también permite cuantificar su gravedad mediante el cálculo del área y la longitud.


En términos de eficiencia del modelo, existe una clara dependencia del rendimiento en función del tamaño del conjunto de datos. Kim et al. (2019) informan de una precisión del 99,98 % con un conjunto de datos

de 40 000 imágenes, lo que corrobora la influencia directa del tamaño de los datos de entrenamiento en la robustez de las RNC. Sin embargo, trabajos recientes como el de Shi et al. (2025) muestran que las técnicas de regularización, como el abandono y los núcleos 4×4 , permiten alcanzar precisiones del 98,81 % con bases de datos considerablemente más pequeñas (3200 imágenes). Estos hallazgos indican una tendencia hacia la optimización algorítmica, que minimiza los requisitos de recopilación de datos sin comprometer la fiabilidad del diagnóstico.

El análisis de estos resultados pone de relieve la superioridad del aprendizaje profundo sobre los métodos computacionales tradicionales. Por ejemplo, Hoang (2019), que utiliza filtros orientables y LSSVM, registra el rendimiento más bajo de la muestra (85,33 %), lo que pone de manifiesto las limitaciones de los descriptores de imágenes manuales para generalizar ante las variaciones de iluminación y textura típicas de las fotografías de materiales estructurales. Por el contrario, las DNN aprenden estas características de forma automática y jerárquica, superando el ruido visual mediante arquitecturas residuales (ResNet) o generativas (CrackGAN), que optimizan la detección de fallos en entornos complejos.

Además, los parámetros de evaluación han evolucionado más allá de la simple precisión. Zhang et al. (2019) incorporan el mIoU (intersección media sobre unión) con un valor del 86,05 %, una medida más estricta que evalúa la correspondencia píxel a píxel entre las predicciones y los daños reales. En resumen, las pruebas sitúan a las RNC, en particular aquellas con mecanismos avanzados de atención o segmentación, como la herramienta estándar para automatizar las inspecciones de infraestructuras, lo que permite una supervisión preventiva más rápida, objetiva y escalable que las inspecciones visuales humanas tradicionales.

Figura 5. Distribución por arquitectura y rango de precisión



Existe una clara tendencia hacia la alta eficiencia en las arquitecturas de aprendizaje profundo analizadas. A primera vista, la familia CNN destaca como el estándar de máximo rendimiento, con la mayoría de sus instancias alcanzando puntuaciones entre el 98 % y el 100 %. Este comportamiento sugiere no solo una arquitectura optimizada, sino también una capacidad de extracción de características extremadamente precisa para el conjunto de datos evaluado, superando en consistencia a los modelos tradicionalmente robustos.

Por otro lado, la arquitectura ResNet se posiciona como la más estable y predecible del estudio. Al concentrar cuatro de sus modelos exclusivamente en el rango del 95-98 %, demuestra que sus mecanismos de aprendizaje residual permiten una convergencia de alta fidelidad sin las fluctuaciones de rendimiento que presentan otras familias. A diferencia de VGG, que muestra una mayor dispersión entre los rangos medio y excelente, ResNet ofrece resultados garantizados en niveles críticos de precisión, lo que la convierte en la opción técnica más confiable para entornos de producción.

La matriz subraya una mejora en la técnica donde las redes convolucionales modernas y residuales dominan una eficiencia elevada. No obstante, la variabilidad observada en las arquitecturas como GoogLeNet o VGG

refuerza la necesidad de una selección de hiperparámetros meticulosa, ya que su arquitectura por sí sola no garantiza el acceso a los rangos de precisión más elevados.

4.1. Aportes y vacíos

Los autores proponen diversas arquitecturas de redes neuronales convolucionales (RNC) para el desarrollo y entrenamiento de modelos de detección de daños estructurales. Aunque los resultados exhiben precisiones elevadas en general, se observan variaciones significativas asociadas al tamaño de la muestra y las dimensiones de las imágenes procesadas. Estas diferencias en precisión dependen principalmente de las arquitecturas empleadas o sus combinaciones híbridas, lo que resalta la influencia del diseño modelo en el rendimiento diagnóstico.

Por ende, el volumen de muestreo incide de manera notable, generando un rango de variabilidad en la precisión de aproximadamente $\pm 5\%$, interpretable como un error inherente a las muestras analizadas en cada arquitectura estudiada por los autores.

La detección de daños en materiales estructurales mediante imágenes fotográficas se limita a la percepción bidimensional (2D), un factor clave para identificar el tipo de patología, pero insuficiente para cuantificar su profundidad. En el caso de grietas, es posible estimar su ancho con relativa precisión; no obstante, la profundidad y sus variaciones espaciales permanecen inaccesibles desde esta perspectiva planar.

Aunque las redes neuronales convolucionales (RNC) se entrenan con atributos como la cantidad de píxeles, decoloración y texturas visibles, e integran mapas de calor para inferir aproximaciones de profundidad, estas estimaciones aún carecen de precisión suficiente. Por tanto, resulta imperativo desarrollar análisis integrales que conjunten múltiples arquitecturas para entrenar modelos híbridos más robustos.

5. CONCLUSIONES

La revisión sistemática confirma que las redes neuronales convolucionales (CNN) representan un cambio de paradigma en la detección automatizada de patologías estructurales en el hormigón armado, superando las limitaciones de las inspecciones visuales manuales en términos de objetividad, eficiencia y escalabilidad. Las arquitecturas evolucionaron desde clasificadores como AlexNet y VGG16 hasta modelos de segmentación semántica como FCN-ResNet18 y CrackGAN, que alcanzan precisiones superiores al 98 % en conjuntos de datos reales, con métricas avanzadas como mIoU (hasta el 86,05 %) que cuantifican no solo la presencia, sino también la geometría precisa de daños como grietas y delaminaciones.

Las técnicas de transferencia de aprendizaje y regularización (por ejemplo, dropout, núcleos 4×4) optimizan el rendimiento incluso con muestras pequeñas (por ejemplo, 3200 imágenes), lo que reduce la dependencia de bases de datos masivas (hasta 60 000 imágenes) y facilita las aplicaciones prácticas a través de drones y dispositivos móviles. Los conjuntos híbridos y las herramientas de interpretabilidad, como Grad-CAM, garantizan la solidez y la fiabilidad, lo que posiciona a las RNC como el estándar para la supervisión preventiva en infraestructuras críticas.

Sin embargo, siguen existiendo lagunas importantes: la percepción bidimensional limita la estimación de la profundidad de las grietas, a pesar de las aproximaciones mediante mapas de calor, y las variaciones en la precisión ($\pm 5\%$) subrayan la necesidad de un muestreo estandarizado y una validación cruzada. Las investigaciones futuras deberían dar prioridad a los modelos 3D multimodales, la fusión con sensores LiDAR y los puntos de referencia globales.

6. REFERENCIAS BIBLIOGRÁFICAS

- ▶ Abubakr, M., Rady, M., & Badran, K. (2024). Application of deep classification of reinforced concrete bridges. *Ain Shams Eng*, 1(1), 12-54. <https://doi.org/10.1016/j.asej.2023.102297>
- ▶ Adhikari, R., Moselhi, O., & Bagchi, A. (2018). Tracking of defects in reinforced concrete bridges using digital im. *Comput. Civ. Eng*, 29(5), 30-56. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000566](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000566)
- ▶ Baral, A., & Singh, V. (2023). Evaluating the Performance of ResNet-50 and GoogleNet for Damage Detection and Classification. *Frcs-cinse*, 6(2), 3-57. <https://doi.org/10.1109/ic-ses63445.2024.10763274>
- ▶ Borin, P. (2019). Condition assessment of RC bridges, integrating machine learning, photogrammetry and BIM, *Int. Archives of the Photogrammetry. Remote Sensing and Spatial Information Sciences*, 3(2), 37-85. <https://doi.org/10.5194/isprs-archives-XLII-2-W15-201-2019>
- ▶ Cardellicchio, A., Ruggieri, S., & Nettis, A. (2022). Deep learning approaches for image-based detection and classification of structural defects in bridges, *Image analysis and processing. ICIAP*, 42(3), 269-279. https://doi.org/10.1007/978-3-031-13321-3_24
- ▶ Diez, A., Khoa, D., & Makki, M. (2019). A clustering approach for structural health monitoring on bridges. *Civ. Struct. Health Monit*, 6(3), 429-445. <https://doi.org/10.1007/s13349-016-0160-0>
- ▶ Gomera, M., & Ballim, Y. (2022). An artificial intelligence approach to detection and assessment of concrete cracks based on visual inspection photographs. *MATEC*, 23(5), 23-31. <https://doi.org/10.1051/mateconf/202236405020>
- ▶ He, K., Zhang, X., Ren, S., & Sun, J. (2018). Deep Residual Learning for Image Recognition. *Conference on Computer Vision and Pattern Recognition*, 32(3), 770-778.
- ▶ Hoang, N.-D. (2019). Image Processing-Based Recognition of Wall Defects Using Machine Learning Approaches and Steerable Filters. *Hindawi*, 36(4), 1-18. <https://doi.org/10.1155/2018/7913952>
- ▶ Holm, E., Transeth, A., & Knudsen, O. (2019). Classification of Corrosion and Coating Damages on Bridge Constructions from Images using Convolutional Neural Networks. *Twelfth International Conference on Machine Vision*, 35(14), 15-63. <https://doi.org/10.1117/12.2557380>
- ▶ Islam, M., & Kim, J.-M. (2019). Vision-Based Autonomous Crack Detection of Concrete Structures Using a Fully Convolutional Encoder-Decoder Network. *Sensors*, 3(1), 32-46. <https://doi.org/10.3390/s19194251>
- ▶ Jung, W., Naveed, F., Hu, B., Wang, J., & Li, N. (2019). Exploitation of deep learning in the automatic detection of cracks on paved roads. *researchpress*, 6(2), 29-46. <https://doi.org/10.1139/geomat-2019-0008>
- ▶ Kim, A.-R., Byun, Y.-S., Chun, C., Kim, D., & Lee, S.-W. (2019). Automated Concrete Crack Detection and using Deep leaning and Image Processing Method. *Advances in Structural Engineering and Mechanics*, 2(1), 14-31.
- ▶ Kim, B., & Cho, S. (2018). Automated Vision-Based Detection of Cracks on Concrete Surfaces Using a Deep Learning Technique. *Sensors*, 8(5), 58-73. <https://doi.org/10.3390/s18103452>
- ▶ Kim, B., & Cho, S. (2019). Automated Vision-Ba-

sed Detection of Cracks on Concrete Surfaces Using a Deep Learning Technique. *sensors*, 5(3), 18-39. <https://doi.org/10.3390/s18103452>

- ▶ Koch, C., Doycheva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2018). Corrigendum to “A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure”. *Advanced Engineering Informatics*, 29(2), 196–210. <https://doi.org/10.1016/j.aei.2016.03.002>
- ▶ Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., & Fieguth, P. (2020). review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. *Manuscript*, 35(7), 56-102. <https://doi.org/10.1016/j.aei.2015.01.008>
- ▶ Leal da Silva, W. R., & Schwerz de Lucena, D. (2018). Concrete Cracks Detection Based on Deep Learning Image Classification. *Proceedings*, 26(2), 56-62. <https://doi.org/10.3390/ICEM18-05387>
- ▶ Lee, H. (2019). Position-invariant neural network for digital pavement crack analysis. *Comput. Civ. Infrastruct. Eng.*, 19(2), 105-118. <https://doi.org/10.1111/j.1467-8667.2004.00341>
- ▶ Li, S., & Zhao, X. (2019). Image-Based Concrete Crack Detection Using Convolutional Neural Network and Exhaustive Search Technique. *Hindawi*, 34(3), 1-12. <https://doi.org/doi.org/10.1155/2019/6520620>
- ▶ Loverdos, D., & Sarhosis, V. (2024). Pixel-level block classification and crack detection from 3D reconstruction models of masonry structures using convolutional neural networks. *Engineering Structures*, 36(7), 118-164. <https://doi.org/10.1016/j.engstruct.2024.118113>
- ▶ Lui, A., Chan, Y., & Leung, F. (2021). *Modelling of destinations for data-driven pedestrian trajectory prediction in public buildings*. IEEE. <https://doi.org/10.1109/BigData52589.2021.9671813>
- ▶ Lui, A., Chan, Y., & Leung, M. (2022). Modelling of pedestrian movements near an amenity in walkways of public buildings. *Control, Automation and Robotics*, 8(3), 394–400. <https://doi.org/10.1109/ICCAR55106.2022.9782667>
- ▶ Mathavan, S., Rahman, M., & Kamal, K. (2018). Use of a self-organizing map for crack detection in highly textured pavement images. *Infrastruct. Syst*, 21(3), 23-64. [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.000023](https://doi.org/10.1061/(ASCE)IS.1943-555X.000023)
- ▶ Mei, Q., & Gül, M. (2020). Multi-level feature fusion in densely connected deep-learning architecture and depth-first search for crack segmentation on images collected with smartphones . *Struct. Health Monit.*, 19(6), 1726–1744. <https://doi.org/10.1177/1475921719896813>
- ▶ Moreh, F., Hasan, Y., Haider Rizvi, Z., Tomforde, S., & Wuttke, F. (2025). Hybrid neural network method for damage localization in structural health monitoring. *Scientific Reports*, 16(3), 15-31. <https://doi.org/10.1038/s41598-025-92396-9>
- ▶ Pereira Junior, W. M., da Silva, S. F., Rodrigues e Silva, A., Ferreira Rezio, L. H., Pereira da Silva, M., da Silva Guimarães, N. R., & Carvalho Canuto, S. D. (2024). Avaliação da presença de fissuras em imagens de estruturas de concreto através do uso de redes neurais profundas. *Revista Materia*, 29(4), 1-14. <https://doi.org/10.1590/1517-7076-RMAT-2024-0354>
- ▶ Perez, H., Tah, J., & Mosavi, A. (2019). Deep Learning for Detecting Building Defects Using Convolutional Neural Networks. *Sensors*, 19(16), 23-53. <https://doi.org/10.3390/s19163556>

- ▶ Rahman, K., & Ahmed, N. (2021). Data-driven shear strength prediction of steel fiber reinforced concrete. *Eng. Struct.*, 233(3), 151-187. <https://doi.org/10.1016/j.engstruct.2020.111743>
- ▶ Savino, P., & Tondolo, F. (2021). Automated classification of civil structure defects based on convolutional neural network. *Front. Struct.*, 15(2), 305–317. <https://doi.org/10.1007/s11709-021-0725-9>
- ▶ Sepasgozar, M., Shirowzhan, S., & Mohammadi, G. (2021). Applications of object detection in modular construction based on a comparative evaluation of deep learning algorithms. *Constr. Innov.*, 20(1), 141–159. <https://doi.org/10.1108/CI-02-2020-0017>
- ▶ Sharma, A. (2019). patch-based convolutional neural network for remote sensing image classification. *Neural*, 3(1), 19-28. <https://doi.org/10.1016/j.neunet.2017.07.017>
- ▶ Shi, Y., Wang, R., & Bai, X. (2025). IDENTIFICATION OF THE DAMAGE TYPES FOR REINFORCED. *Mater Tehnol*, 59(4), 631–638. <https://doi.org/10.17222/mit.2025.1438>
- ▶ Simler, C., Trostmann, E., & Berndt, D. (2019). Automatic crack detection on concrete floor images. *Education in Measurement Science*, 25(6), 15-26. <https://doi.org/10.1117/12.2531951>
- ▶ Sitara, S., Kavitha, S., & Raghuraman, G. (2018). Review and Analysis of Crack Detection and Classification Techniques based on Crack Types. *International Journal of Applied Engineering*, 13(8), 6056-6062. <https://doi.org/10.37622/IJAER/13.8.2018.6056-6062>
- ▶ Spencer, B., Hoskere, V., & Narazaki, Y. (2021). *Advances in computer vision based civil infrastructure inspection and monitoring*, Engineering. SEVG. <https://doi.org/10.1016/j.eng.2018.11.030>
- ▶ Wang, B., Li, Y., Zhao, W., Zhang, Z., Zhang, Y., & Wang, Z. (2020). Effective Crack Damage Detection Using Multilayer Sparse Feature Representation and Incremental Extreme Learning Machine. *Applied Sciences*, 42(3), 25-68. <https://doi.org/10.3390/app9030614>
- ▶ Wang, N., Zhao, Q., Li, S., Zhao, X., & Zhao, P. (2018). Damage Classification for Masonry Historic Structures Using Convolutional Neural Networks Based on Still Images. *Computer - Aided*, 3(2), 52-72. <https://doi.org/10.1111/micc.12411>
- ▶ Werle Tozevich, L. G., Librelotto, G. R., & Tozevich, P. L. (2024). Classificac,ao de patologias em estruturas usando redes neurais convolucionais: diferenciacao em trincas, fissuras e rachaduras. *Compet*, 23(3), 73-86. <https://doi.org/10.59022448190485429>
- ▶ Xu, H., Su, X., Wang, Y., Cai, H., Cui, K., & Chen, X. (2019). Automatic Bridge Crack Detection Using a Convolutional Neural Network. *Applied sciences*, 2(2), 1-14. <https://doi.org/10.3390/app9142867>
- ▶ Xu, Y., Wei, S., & Bao, Y. (2023). Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network. *Structural Control & Health Monitoring*, 3(1), 23-85. <https://doi.org/10.1002/STC.2313>
- ▶ Yao, Y., Tung, T. E., & Glisic, B. (2018). Crack detection and characterization techniques – An overview, *Struct. Control Health Monit*, 21(12), 1387–1413. <https://doi.org/10.1002/stc.1655>
- ▶ Zhang, J., Lu, C., Wang, J., Wang, L., & Yue, X.-G. (2019). Concrete Cracks Detection Based on FCN with Dilated Convolution. *Applied Sciences*, 26(9), 20-40. <https://doi.org/10.3390/app9132686>

- ▶ Zhang, K., Zhang, Y., & Cheng, H. (2020). Crac-
kGAN: Pavement Crack Detection Using Partially
Accurate Ground Truths Based on Generative Ad-
versarial Learning. *arXiv*, 20(2), 1-14. [https://doi.
org/10.1109/TITS.2020.2990703](https://doi.org/10.1109/TITS.2020.2990703)
- ▶ Zhang, L., Yang, F., Zhang, Y. D., & Zhu, Y. J.
(2022). ROAD CRACK DETECTION USING
DEEP CONVOLUTIONAL NEURAL NE-
TWORK. *Temple*, 3(1), 12-29. [https://doi.or-
g/10.1109/ICIP.2016.7533052](https://doi.org/10.1109/ICIP.2016.7533052)
- ▶ Zheng, J., & Liao, C. (2021). Damage identifi-
cation based on convolutional neural network
and recurrence graph for beam bridge. *Struct.
Health Monit*, 20(4), 1392–1408. [https://doi.
org/10.1177/1475921720916928](https://doi.org/10.1177/1475921720916928)
- ▶ САВИЦЬКИЙ, В., ДАНШЕВСЬКИЙ, В.,
& ГАЙДАР, А. (2023). ІДЕНТИФІКАЦІЯ
ТРИЩИНУ ВЕРТИКАЛЬНИХ ЕЛЕМЕНТАХ
БУДІВЕЛЬНИХ КОНСТРУКЦІЙ
ЗА ДОПОМОГОЮ ЗГОРТКОВИХ
НЕЙРОННИХ МЕРЕЖ. *Український
журнал будівництва та архітектури*,
14(2), 1-14. [https://doi.org/10.30838/J.BPSA-
CEA.2312.250423.65.933](https://doi.org/10.30838/J.BPSA-CEA.2312.250423.65.933)