

DESARROLLO DE MODELO DE DEEP VISION PARA LA DETECCIÓN Y SEGMENTACIÓN DE PATOLOGÍAS EN ESTRUCTURAS DE H°A°

Ing. De Luca, Franco^a

Dr. Ing. Turello, Diego^b; Dr Ing. Pinto, Federico^b

^aFacultad de Ciencias Exactas, Físicas y Naturales, franco.de.luca@mi.unc.edu.ar

^bFacultad de Ciencias Exactas, Físicas y Naturales, diego.turello@unc.edu.ar;
fpinto@unc.edu.ar

Palabras clave: patologías del hormigón; deep learning; visión artificial; inspección estructural.

RESUMEN

Se presenta un sistema automatizado para la detección y segmentación de patologías en estructuras de hormigón mediante técnicas de Deep Learning, basado en la identificación de fisuras, desprendimientos, corrosión y eflorescencias. Se implementó un modelo YOLOv8s-seg entrenado sobre el dataset S2DS (re-anotado y adaptado), con estrategias de preprocesamiento propias: conversión de máscaras al formato YOLO, particionado de imágenes (patching), enfoque de sliding window y protocolo de anotación iterativo. El modelo alcanzó un mAP@0.5 de 0,733 sobre el conjunto de test, con buen desempeño en las clases de mayor relevancia estructural. Se desarrolló además un pipeline de inspección mediante drones con georreferenciación automática de detecciones, validado en dos casos de estructuras reales en Córdoba. Los resultados muestran que el enfoque propuesto constituye una herramienta eficaz para asistir la inspección estructural, mejorando su eficiencia y objetividad sin reemplazar la validación profesional.

ABSTRACT

This paper presents an automated system for the detection and segmentation of pathologies in concrete structures using Deep Learning techniques, targeting cracks, spalling, corrosion, and efflorescence. A YOLOv8s-seg model was trained on the S2DS dataset (re-annotated and adapted), incorporating mask-to-YOLO conversion, image patching, a sliding window approach and an iterative annotation protocol. The model achieved a mAP@0.5 of 0.733 on the test set, with strong performance across structurally critical classes. A drone-based inspection pipeline with automatic defect geolocation was developed and validated on two real structures in Córdoba. Results confirm the proposed approach as an effective tool to support structural inspection, improving efficiency and objectivity without replacing expert engineering judgment.

INTRODUCCIÓN

Las estructuras de hormigón armado están expuestas a lo largo de su vida útil a agentes físicos, químicos y ambientales que generan patologías tales como fisuras, desprendimientos, corrosión de armaduras y eflorescencias. La identificación y el monitoreo temprano de estos síntomas son indispensables para garantizar la seguridad estructural y optimizar los recursos de mantenimiento¹.

Tradicionalmente, la evaluación del estado de estas estructuras se realiza mediante inspecciones visuales llevadas a cabo por profesionales especializados. Este proceso es intensivo en tiempo, dependiente de la experiencia del inspector y susceptible a errores asociados a la fatiga o a la subjetividad en la interpretación. Para estructuras de gran escala o difícil acceso como: tanques elevados; presas; puentes o silos, las limitaciones son aún más pronunciadas.

La Ley de Sitter establece que el costo de intervención crece geométricamente con el avance del deterioro, haciendo de la detección temprana la estrategia más eficiente tanto técnica como económicamente¹.

En este marco, los avances en Deep Learning (DL), y en particular las redes neuronales convolucionales (CNNs), han abierto nuevas posibilidades para la automatización del análisis de imágenes en ingeniería civil. El presente trabajo propone el desarrollo de un modelo de visión artificial para la detección y segmentación semántica de patologías en estructuras de hormigón, combinado con un pipeline de inspección mediante drones y georreferenciación de detecciones, y validado en casos reales; con el fin de optimizar los procesos de inspección estructural.

PATOLOGÍAS CONSIDERADAS Y SU RELEVANCIA ESTRUCTURAL

Se consideran los síntomas patológicos detectables mediante análisis de imágenes de la superficie de estructuras de hormigón armado, que constituyen indicadores de mecanismos de deterioro con incidencia directa sobre el comportamiento estructural. La *Tabla 1* resume las cinco clases de patologías abordadas.

CLASE	MANIFESTACIÓN VISIBLE	RELEVANCIA ESTRUCTURAL
Fisuras (Crack)	Discontinuidades lineales en superficie; geometría longitudinal, transversal o en mapa	Indican tensiones que superan la resistencia a tracción; facilitan ingreso de agentes agresivos (CO ₂ , cloruros, humedad)
Desprendimientos (Severos o <i>spalling</i>)	Pérdida localizada de material; exposición de áridos y/o armaduras	Reducen el recubrimiento protector; aceleran la corrosión de armaduras y comprometen la capacidad resistente
Corrosión (Corrosion)	Manchas de óxido; fisuras longitudinales paralelas a barras	Genera productos de mayor volumen que el acero; puede comprometer su sección transversal y provoca fisuración y desprendimiento del recubrimiento
Eflorescencias (Efflorescence)	Depósitos blanquecinos cristalinos en superficie	Indica transporte de fluidos en el interior de la estructura; puede favorecer la corrosión de armaduras
Vegetación (Vegetation)	Crecimiento biológico sobre el hormigón	Retiene humedad; favorece la penetración de raíces en fisuras y acelera el deterioro favoreciendo otras patologías

Tabla 1. Clases de patologías consideradas, sus manifestaciones visuales y relevancia estructural.

METODOLOGÍA

Los problemas de detección y segmentación de imágenes son típicamente tratados a través de CNNs, partiendo de esta base los modelos de inteligencia artificial (IA) preentrenados, e implementando otras técnicas de mejora y ajuste para el reconocimiento de objetos. Por lo tanto, una vez definida el algoritmo base del modelo, resta establecer una de las partes más críticas dentro de los problemas del aprendizaje automático, la obtención de un dataset adecuado y representativo para el entrenamiento del mismo^{2,3}.

Se utilizó el set de datos S2DS (Structural Defects Dataset)⁴, compuesto por 743 imágenes de 1024 x 1024 px de superficies de estructuras de hormigón con manifestaciones patológicas, las cuales contenían anotaciones de segmentación semántica para las cinco clases de patologías descritas en la *Tabla 1*.

La distribución del dataset original se resume en la *Tabla 2*. La distribución entre clases es relativamente equilibrada, con la clase más frecuente (corrosión, 29,7%) y la menos frecuente (vegetación, 13,1%) sin presentar un desbalance severo que condicione el aprendizaje. Las particiones de entrenamiento, validación y test mantienen proporciones similares entre clases.

CLASE	ENTRENAMIENTO		VALIDACIÓN		TEST	
	Instancias	%	Instancias	%	Instancias	%
FISURAS (Crack)	1.158	23,3%	123	22,4%	165	24,7%
DESPRENDIMIENTOS (Spalling)	802	16,1%	93	17,0%	96	14,4%
CORROSIÓN (Corrosion)	1.477	29,7%	189	34,5%	223	33,4%
EFLORESCENCIAS (Efflorescence)	793	15,9%	72	13,1%	96	14,4%
VEGETACIÓN (Vegetation)	653	13,1%	58	10,6%	76	11,4%
PUNTO CONTROL (Control Point)	96	1,9%	13	2,4%	12	1,8%
TOTAL	4.979	100%	548	100%	668	100%

Tabla 2. Distribución de instancias por clase en los conjuntos de entrenamiento, validación y test.

Para el desarrollo de la herramienta de detección y segmentación semántica de patologías, se optó por emplear la reconocida arquitectura open-source de Ultralytics denominada YOLO (You Only Look Once)⁵, la cual brinda modelos preentrenados para el reconocimiento de objetos en fotos y videos. Los modelos de la familia YOLO destacan por su capacidad de inferencia en tiempo real con un balance adecuado entre precisión y eficiencia computacional, lo que los hace más adecuados que arquitecturas encoder-decoder de mayor costo computacional, como U-Net, para escenarios de inspección que requieren procesar grandes volúmenes de imágenes⁶.

En el caso particular de este trabajo, se empleó la arquitectura Yolov8s-seg (versión small de la familia YOLOv8 con capacidades de segmentación semántica), inicializada con pesos preentrenados sobre el dataset COCO (Common Objects in Context)⁵. Este enfoque de transfer learning permitió partir de representaciones visuales consolidadas —bordes, texturas, patrones generales— y adaptarlas al dominio específico de patologías en hormigón mediante fine-tuning, sin necesidad de entrenar la red desde cero.

El dataset original presentaba anotaciones de las patologías en formato de máscaras de color por clase. Se desarrollaron scripts en Python (utilizando principalmente la librería OpenCV) para la conversión de las máscaras al formato poligonal requerido por YOLOv8-seg para ser interpretado. A partir del análisis de las primeras corridas del modelo, se identificaron tres limitaciones principales y se implementaron las siguientes estrategias de mejora:

- Patching (fragmentación): las imágenes originales se subdividieron en subregiones de 512×512 px, preservando la resolución local de los defectos. Esto resultó crítico para la detección de fisuras de pequeño espesor y otros defectos, que resultaban imperceptibles al redimensionar la imagen completa a la resolución de entrada del modelo (*Figura 1*). Cabe distinguir este esquema del enfoque multi-escala empleado durante la inferencia en campo, descripto más adelante en la sección Pipeline, donde se utilizan ventanas deslizantes de ≈ 320 , 640 y 1.280 px sobre imágenes de alta resolución.
- Dilatación de máscaras de fisuras: se aplicó un engrosamiento controlado de los polígonos de la clase crack, aumentando su área efectiva para mejorar su representatividad durante el entrenamiento y reducir los falsos negativos (*Figura 2*).
- Protocolo de anotación iterativo: se definieron criterios técnicos uniformes para la identificación y delimitación de patologías, y se realizaron ciclos iterativos de revisión y corrección de anotaciones utilizando las predicciones del modelo en entrenamiento como método de diagnóstico, a través de herramientas como Computer Vision Annotation Tool (CVAT) y Label Studio. La *Figura 3* ilustra el resultado de este proceso, comparando anotaciones originales y refinadas para la clase eflorescencia. La *Figura 4* complementa este análisis mostrando casos en que las predicciones del modelo fueron utilizadas como diagnóstico: en ellos se observan confusiones propias del modelo como detección parcial de eflorescencia, delimitación incompleta en el ground truth (GT), trazos de tiza confundidos como eflorescencia y falta de detección de spalling, que motivaron correcciones concretas en el dataset.

Caso 1



Patch 1



Patch 2



Caso 2



Patch 1



Patch 2






Figura 1. Fragmentación de imágenes mediante patching.



Imagen original de una fisura (S2DS)



Máscara de segmentación original (S2DS)



Máscara de segmentación engrosada

Figura 2. Proceso de engrosamiento de máscaras en la clase fisura (crack).





Figura 3. Comparación entre las anotaciones originales (izquierda) y las anotaciones refinadas (derecha) para la clase eflorescencia del dataset S2DS.




Figura 4. Comparación entre imagen original, anotaciones originales (ground truth, GT) y la predicción generada por el modelo utilizado como diagnóstico.

El entrenamiento se realizó en el entorno Google Colab utilizando gratuitamente una GPU NVIDIA T4, con imágenes de entrada de 512×512 px (parches). Se evaluaron cuatro versiones evolutivas del modelo, observándose una mejora progresiva del mAP@0.5 desde 0,532 hasta 0,729 como resultado del refinamiento iterativo del dataset, la implementación del patching y la dilatación de máscaras.

RESULTADOS CUANTITATIVOS DEL MODELO

Las métricas empleadas para evaluar el modelo provienen del campo del aprendizaje automático. Para su comprensión, se definen previamente los conceptos de Verdadero Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) y Verdadero Negativo (VN), evaluados para cada clase de patología: un **VP** ocurre cuando el modelo detecta una patología que efectivamente existe y la segmenta con una superposición geométrica suficiente respecto a la anotación real ($IoU \geq 0,5$); un **FP** ocurre cuando el modelo detecta una patología que no existe o la clasifica erróneamente (detección espuria o confusión entre clases); un **FN** ocurre cuando una patología real no es detectada por el modelo (omisión); y un **VN** corresponde a regiones sin patología que el modelo correctamente no detecta.

A partir de estas definiciones, la **Precisión** y el **Recall** se expresan como:

$$P = VP / (VP + FP) \quad (1)$$

$$R = VP / (VP + FN) \quad (2)$$

La precisión indica qué proporción de las detecciones realizadas corresponde efectivamente a la clase indicada; el recall (sensibilidad) indica qué proporción de las instancias reales de una patología fue detectada. Ambas métricas dependen del umbral de confianza empleado: un umbral bajo aumenta el recall a expensas de la precisión, y viceversa. En inspección estructural, minimizar los FN (patologías no detectadas) es prioritario respecto a minimizar los FP, dado que la omisión de un síntoma real tiene consecuencias más críticas que una sobre-detección filtrable por el profesional.

Para eliminar la dependencia del umbral de confianza, se emplea la **AP@0.5** (*Average Precision*) por clase, que integra el comportamiento precisión-recall a lo largo de todos los umbrales posibles, considerando una detección válida cuando la superposición geométrica entre predicción y ground truth supera el 50% ($IoU \geq 0,5$). El **mAP@0.5** es el promedio de los AP@0.5 de todas las clases y constituye el indicador global de comparación entre modelos. La **matriz de confusión normalizada** permite visualizar, para un umbral de confianza fijo, qué proporción de instancias de cada clase fue correctamente clasificada y cuál fue confundida con el fondo u otras clases.

La *Tabla 3* presenta el desempeño del modelo final evaluado sobre el conjunto de test, expresado en métricas de segmentación de instancias (máscaras). El modelo alcanzó un mAP@0.5 de 0,733 sobre el test set, con un valor de 0,765 sobre el conjunto de validación, lo que indica una adecuada capacidad de generalización sin evidencias de sobreajuste (overfitting). Cabe destacar que la clase vegetación presenta la mayor caída en AP@0.5 respecto a las clases de mayor relevancia estructural, alcanzando 0,610, lo que se atribuye a su alta variabilidad visual (musgos, líquenes, plantas de distinto tipo y tamaño) combinada con su menor representación relativa en el dataset (13,1% de instancias de entrenamiento). Las clases fisuras, desprendimientos y corrosión — de mayor incidencia estructural — alcanzan AP@0.5 entre 0,708 y 0,718, confirmando la capacidad del modelo para detectar los síntomas de mayor criticidad.


CLASE	P	R	AP@0.5 (Test)	AP@0.5:0.95 Test
Fisuras (Crack)	0,707	0,642	0,708	0,356
Desprendimientos (Spalling)	0,720	0,615	0,718	0,489
Corrosión (Corrosion)	0,870	0,538	0,713	0,440
Eflorescencias (Efflorescence)	0,679	0,594	0,655	0,404
Vegetación (Vegetation)	0,750	0,434	0,610	0,498
Punto Control (Control Point)	1,00	1,00	0,995	0,950
mAP@0.5Val mAP@0.5 Test	-	-	0,733	0,523

Tabla 3. Desempeño del modelo final por clase (mAP@0.5) sobre conjuntos de validación y test.


Nota: P y R evaluados a umbral de confianza 0,5 ($IoU \geq 0,5$). Métricas de segmentación de instancias (máscaras).

A un nivel de confianza de 0,5, la precisión por clase oscila entre 0,679 (eflorescencias) y 1,000 (punto de control), mientras que el recall presenta mayor variabilidad, con valores entre 0,434 (vegetación) y 1,000 (punto de control). La clase vegetación exhibe el recall más bajo (0,434), coherente con la caída observada en AP@0.5 respecto a validación (*Figura 5*), atribuible a su alta variabilidad visual. Las clases de mayor relevancia estructural (fisuras, desprendimientos y corrosión) alcanzan AP@0.5 entre 0,708 y 0,718, con precisiones superiores a 0,70. El mAP@0.5:0.95 global de 0,523 indica que el modelo mantiene detecciones geométricamente precisas a umbrales de superposición aún más exigentes, aunque con mayor margen de mejora respecto al mAP@0.5.

La mejora evolutiva del modelo puede apreciarse al comparar las curvas *precision-recall* del modelo inicial sin las técnicas de mejora, con la versión final, donde puede verse claramente la mejoría en la segmentación de las patologías, especialmente en las clases *crack* y *spalling* (*Figura 5*). Estos resultados fueron producto de las correcciones iterativas en el conjunto de los datos, las técnicas de mejora del aprendizaje y procesos de *fine tuning* a partir de cada nueva optimización del modelo.



Curva PR del modelo inicial



Curva PR del modelo final

Figura 5. Comparativa de Curvas Precisión-Recall del entrenamiento del modelo inicial y final.

Al analizar la matriz de confusión del modelo final, se revela un comportamiento consistente: cuando el modelo detecta un defecto, lo clasifica correctamente en la gran

mayoría de los casos (baja confusión entre clases distintas). La principal limitación se asocia a la presencia de falsos negativos (patologías reales clasificadas como fondo), particularmente en las clases efflorescence ($\approx 36\%$), corrosion ($\approx 31\%$) y spalling ($\approx 26\%$) como se observa en la *Figura 6*.




Figura 6. Matriz de confusión normalizada del modelo final sobre el conjunto de validación

El análisis de la curva recall-confidence (*Figura 7*) evidenció que el recall se mantiene elevado para umbrales bajos y medios, disminuyendo significativamente por encima de 0,5–0,6. En consecuencia, para la aplicación práctica del modelo se propone la utilización de umbrales de confianza relativamente bajos (del orden de 0,3 a 0,4 según la clase), priorizando la sensibilidad en la detección por sobre la precisión. Esta decisión es coherente con criterios de seguridad estructural, donde la omisión de patologías reales tiene consecuencias más críticas que la sobre-detección, la cual puede ser posteriormente filtrada por el profesional a cargo.




Figura 7. Curva Recall-Confidence del modelo final sobre el conjunto de validación.

PIPELINE DE DETECCIÓN Y GEORREFERENCIACIÓN

Con el objetivo de trasladar el modelo a condiciones reales de inspección de estructuras de gran escala, se desarrolló un pipeline completo que integra las siguientes etapas:

- Adquisición y organización de imágenes mediante vuelo de dron, con extracción de metadatos GPS y de orientación (azimut/bearing).
- Preprocesamiento y fragmentación: implementación de un esquema multi-escala de sliding window con tres resoluciones complementarias (parches de ≈ 320 , 640 y 1.280 px), orientadas respectivamente a reconocer patologías de pequeña, mediana y gran extensión.
- Inferencia con el modelo YOLOv8s-seg, seguida de postprocesamiento: filtrado por umbral de confianza diferenciado por clase, deduplicación de detecciones redundantes entre escalas y dilatación morfológica de máscaras para unificar predicciones en parches adyacentes.
- Georreferenciación relativa: utilizando las coordenadas GPS y el azimut de cada imagen, las detecciones son ubicadas en su posición exacta alrededor de la estructura y asignadas a sectores específicos de la misma (N, S, E, O), generando un mapa interactivo de daño con popups que incluyen miniatura de cada imagen, contador de patologías por clase y datos geográficos.

La *Figura 8* esquematiza las etapas del pipeline:




Figura 8. Esquema general del pipeline desarrollado para la detección y georreferenciación automática de patologías en estructuras de hormigón a partir de imágenes adquiridas con dron. Elaboración propia, con asistencia de herramientas de IA generativa (Gemini) para el diseño gráfico del esquema.

El enfoque multi-escala permitió una mejora significativa en la capacidad de detección respecto al esquema de escala única, al capturar simultáneamente defectos de distintas dimensiones. La contrapartida principal es un incremento aproximado en tres veces del tiempo de inferencia y un aumento en la tasa de falsos positivos en la escala fina, producto de la interpretación de texturas rugosas como posibles patologías.

CASOS DE ESTUDIO

En primera instancia, se analizaron imágenes de vuelo de dron correspondientes a una estructura de contención de carácter industrial de gran dimensión. El modelo fue capaz de identificar satisfactoriamente múltiples patologías superficiales con distribución espacial coherente con los mecanismos de deterioro esperados.

A continuación, se presentan diferentes vistas de la estructura de contención en las cuales se ilustran las detecciones del modelo considerando la totalidad de las clases de patologías. Estas imágenes (Figura 9Figura 11) permiten analizar no solo la presencia individual de defectos, sino también su distribución espacial y la coexistencia de distintos síntomas sobre el paramento, aportando una lectura más integral del estado superficial de la estructura.



Figura 9. Vista general de un paño de la estructura de contención, con detecciones de eflorescencias en zonas de escurrimiento y manchas de corrosión. Colonización biológica leve en la base.



Figura 10. Sector norte con presencia de eflorescencias en coincidencia con zonas de escurrimiento del agua y junta constructiva. Presencia de corrosión de armaduras y pequeño desprendimiento del H° en concurrencia con la armadura longitudinal.



Figura 11. Sector Este con presencia de fisuras verticales y eflorescencias en zonas de filtración del agua y en zonas de fisuración. Puede observarse moho en la unión de la cenefa superior con el paramento inferior producto de la concentración prolongada de humedad en dicha zona.

De las Figura 9, Figura 10 y *Figura 11*, se concluye que las eflorescencias se concentraron en coincidencia con las zonas de escurrimiento de la cenefa superior, posiblemente debido a la ausencia de goterón. En los mismos sectores se identificaron fisuras orientadas según la disposición de las armaduras y desprendimientos localizados, configurando un patrón de deterioro asociado a la presencia prolongada de humedad. La coexistencia de estas manifestaciones, junto con manchas de corrosión, resulta consistente con un proceso de ingreso de agua, transporte de sales hacia la superficie y posible inicio de corrosión de las armaduras.

Como segundo caso, se inspeccionó un tanque de hormigón armado en desuso de aproximadamente 30 m de altura. La estructura se compone de tres tabiques de H°A° con ménsulas superiores para formar la base del tanque y tres semi-anillos de arriostramiento a un tercio y dos tercios de la altura (*Figura 12*).

Este caso presentó un nivel de deterioro significativamente mayor al del caso anterior, con desprendimientos de recubrimiento y armaduras expuestas visibles a distancia. El modelo permitió identificar y localizar de manera sistemática los principales síntomas en toda la superficie de la estructura. La *Figura 13* presenta los casos más representativos.




Figura 12. Vista del tanque analizado (fotografía de Google Street View, arriba) y mapa interactivo de patologías generado sobre imagen satelital base de Esri World Imagery⁷, visualizado mediante la librería Leaflet (abajo).



Figura 13. Detecciones representativas sobre el tanque. Imagen superior: regiones clasificadas como desprendimientos (spalling). Imagen inferior: mapa de detecciones multiclase con la totalidad de las patologías identificadas.

Se identificaron fisuras longitudinales en coincidencia con las armaduras longitudinales de los tabiques, indicadoras de un proceso latente de corrosión interna. La concentración de desprendimientos en los nudos de unión tabique-anillo sugiere un posible honeycomb de ejecución (producto de vibrado deficiente en zonas con alta densidad de armaduras) que habría facilitado el ingreso de agentes oxidantes.

En el sector sur se detectó una concentración significativa de vegetación, coherente con la exposición predominante al viento y la lluvia desde esa dirección en Córdoba y la falta de luz solar, lo que genera condiciones sostenidas de humedad favorables para la colonización biológica.

DISCUSIÓN

Los resultados confirman que el modelo es capaz de identificar y localizar patologías de manera automática en condiciones reales de inspección, con adecuada capacidad de generalización considerando el volumen reducido del dataset de entrenamiento (menos de 750 imágenes originales), lo que evidencia la eficacia de las estrategias de preprocesamiento y fine-tuning implementadas^{2,3}. Resultados similares en términos de capacidad de generalización con datasets reducidos han sido reportados en trabajos de segmentación semántica aplicada a estructuras de hormigón⁸, aunque bajo condiciones de tarea y métricas distintas que dificultan una comparación directa.

Las principales limitaciones observadas son: sensibilidad a fondos complejos no representados en el entrenamiento (techos metálicos oxidados, superficies pintadas), que generan falsos positivos por similitud visual; falsos negativos y confusiones en patologías difusas, donde manchas de humedad no son detectadas o son clasificadas erróneamente como corrosión por falta de ejemplos representativos; y dependencia de la calidad de adquisición, ya que variaciones en iluminación, ángulo y distancia afectan la consistencia de las detecciones, subrayando la importancia de estandarizar el protocolo de relevamiento fotogramétrico.

El modelo no reemplaza el criterio profesional del ingeniero civil, sino que constituye una herramienta de apoyo para la sistematización del análisis visual, la reproducibilidad de las detecciones y el procesamiento de grandes volúmenes de imágenes en tiempos reducidos.

CONCLUSIONES

Se desarrolló e implementó un modelo de visión artificial para la detección y segmentación automática de cinco clases de patologías en estructuras de hormigón armado, alcanzando un mAP@0.5 de 0,765 sobre el conjunto de validación y 0,733 sobre el test set independiente, con adecuada capacidad de generalización.

Las principales contribuciones del trabajo son:

- Conjunto de estrategias de preprocesamiento propias (patching, dilatación de máscaras, protocolo de anotación iterativo) que permitieron superar las limitaciones de un dataset de tamaño reducido.
- Pipeline completo de detección y georreferenciación con enfoque multi-escala, validado en dos casos reales de estructuras de gran escala en Córdoba.
- Protocolo integrado de inspección, diagnóstico e intervención que articula el modelo con programas de mantenimiento preventivo y correctivo, en consonancia con los principios de la Ley de Sitter.

Como líneas de trabajo futuro se destacan: la ampliación del dataset con mayor diversidad de escenarios y patologías (honeycomb, scaling, zonas de reparación); la incorporación de métodos de filtrado espacial para restringir detecciones a la región de interés estructural; la integración con modelos y plataformas BIM; y el desarrollo de marcos normativos que regulen la aplicación de estas herramientas en la práctica profesional de la ingeniería civil argentina.

AGRADECIMIENTOS

El autor del trabajo, Ing. Franco De Luca, agradece a la Facultad de Ciencias Exactas, Físicas y Naturales de la Universidad Nacional de Córdoba por el marco institucional en el que se desarrolló este trabajo y a sus supervisores: Dr. Ing. Diego Turello y Dr. Ing. Federico Pinto, del Centro de Vinculación de Ensayos No Destructivos y Evaluación de Obras de Infraestructura Civil. Se agradece especialmente a la empresa Docta SDI que facilitó el acceso a las imágenes de las estructuras analizadas como casos de estudio.

REFERENCIAS

- 1) Helene, P. (2003). *Manual de Rehabilitación de Estructuras de Hormigón*. CYTED, São Paulo.
- 2) Chollet, F. (2021). *Deep Learning with Python (2nd ed.)*. Manning Publications.
- 3) Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow (2nd ed.)*. O'Reilly Media.
- 4) Benz, C., & Rodehorst, V. (2022). Image-Based Detection of Structural Defects Using Hierarchical Multi-scale Attention. *DAGM German Conference on Pattern Recognition*, 337–353. Springer.
- 5) Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLO (Version 8.0.0)*
- 6) Gallardo-Caballero, R. et al. (2024). Deep Learning Models for UAV-Assisted Bridge Inspection: A YOLO Benchmark Analysis. *arXiv*, 2411.04475.
- 7) Esri. (2024). *World Imagery* [Mapa satelital]. ArcGIS Online. <https://www.esri.com/>
- 8) Shokri, P., Shahbazi, M., & Nielsen, J. (2022). Semantic Segmentation and 3D Reconstruction of Concrete Cracks. *Remote Sensing*, 14(22), 5793.