

Desarrollo de un algoritmo de visión artificial con redes neuronales para la detección de grietas en estructuras de hormigón

Development of an artificial vision algorithm with neural networks for the detection of cracks in concrete structures

Desenvolvimento de um algoritmo de visão artificial com redes neurais para a detecção de rachaduras em estruturas de concreto.

Bartra Aguilar, Kevin Rubén¹

<https://orcid.org/0009-0003-5773-7070>

Montenegro Honores, Carlos Wilfredo²

<https://orcid.org/0009-0005-1660-2449>

Pretell Ramirez, Carlos Andrés³

<https://orcid.org/0009-0003-8017-7032>

Méndez Parodi, Raúl Alfredo⁴

<https://orcid.org/0000-0002-1667-9594>

Recibido: 10.03.2023

Aceptado: 06.05.2023

RESUMEN

Se desarrolló un algoritmo para detectar rajaduras en las estructuras de concreto aplicando la visión artificial y técnicas de procesamiento de imágenes. El algoritmo centra su funcionamiento en una laptop Asus con procesador Intel Core i5 y Windows 11 de 64 bits, que conectado a una cámara de celular con la aplicación iVCam adquiere imágenes del concreto aplicando la técnica de fotografía básica. Las imágenes adquiridas son procesadas dentro de la laptop y se emplean métodos estadísticos y de visión artificial para detectar las anomalías presentes en estructuras de concreto u hormigón tales como fisuras en tarrajeado. A partir de las pruebas realizadas con el algoritmo, se obtuvo como resultado una eficiencia del sistema del 93,02%. Se concluye que la implementación del algoritmo mejora la calidad y buen estado del concreto a la vez permite una mayor eficiencia del proceso, llevando un control de producción diario en una base de datos almacenados.

Palabras clave: Fisuras, procesamiento de imágenes, visión artificial.

ABSTRACT

An algorithm was developed to detect fissures in concrete structures applying artificial vision and image processing techniques. The algorithm centers its operation on an Asus laptop with an Intel Core i5 processor and Windows 11 64-bit, which, connected to a cell phone camera with the iVCam application, acquires images of the concrete applying the basic photography technique. The acquired images are processed within the laptop and statistical methods and artificial vision are used to detect anomalies present in concrete or concrete structures, such as cracks in grouting. From the tests carried out with the algorithm, a system efficiency of 93.02% was obtained as a result. It is concluded that the implementation of the algorithm improves the quality and good condition of the concrete at the same time allows a greater efficiency of the process, carrying out daily production control in a stored database.

Keywords: Fissures, image processing, artificial vision

RESUMO

Foi desenvolvido um algoritmo para detectar fissuras em estruturas de concreto aplicando técnicas de visão artificial e processamento de imagens. O algoritmo centra sua operação em um laptop Asus com processador Intel Core i5 e Windows 11 de 64 bits, que, conectado a uma câmera de celular com o aplicativo iVCam, adquire imagens do concreto aplicando a técnica de fotografia básica. As imagens adquiridas são processadas no laptop e métodos estatísticos e de visão artificial são usados para detectar anomalias presentes no concreto ou em estruturas

¹Universidad Privada del Norte. Trujillo. Perú. Estudiante. N00169722@upn.pe

²Universidad Privada del Norte. Trujillo. Perú. Estudiante. N00216750@upn.pe

³Universidad Privada del Norte. Trujillo. Perú. Estudiante. N0019870@upn.pe

⁴Universidad Autónoma del Perú. Lima. Perú. Doctor. mcndezp@autonoma.edu.pe

de concreto, como fisuras no rejunte. A partir dos testes realizados com o algoritmo, obteve-se como resultado uma eficiência do sistema de 93,02%. Conclui-se que a implementação do algoritmo melhora a qualidade e o bom estado do concreto, ao mesmo tempo em que permite uma maior eficiência do processo, realizando o controle diário da produção em um banco de dados armazenado.

Palavras-chave: Fisuras, processamento de imagens, visão artificial.

Introducción

Actualmente, la calidad de la construcción civil es deficiente debido a la falta de supervisión, el uso de materiales de baja calidad o falta de capacitación de los obreros. Esta problemática da lugar a que las infraestructuras sean inseguras, lo que representa un riesgo para la sociedad y la vida de las personas, obteniendo mantenimientos costosos y reparaciones a largo plazo. En la industria existe un alto índice de automatización, debido a que la tecnología avanza exponencialmente, generando que se desarrollen diversos protocolos industriales dentro del rubro civil. Toda infraestructura civil, se vuelve susceptible al deterioro, perdiendo sus funciones originales Meléndez et al. (2000). Con ello, existen varios factores para detectar la falta de calidad en la infraestructura, un indicador importante de la condición del pavimento es la aparición de grietas, que generalmente aparecen por contracción y dilatación de los materiales Pozzo (2020). Hoy en día es más rigurosa la preparación técnica para que el diseño civil, de inicio a fin sea debidamente aplicado y cumpla con las normativas específicas de una obra segura, duradera y estética Dung (2019). Por ello, se mejora la detección de rajaduras con ciertas técnicas basadas en la aplicación de algoritmos de optimización, ya que estos están ganando importancia a comparación con otros métodos debido a su facilidad de aplicación fiable Krizhevsky et al. (2017). Asimismo, se hace uso de redes neuronales como forma de emular ciertas características propias de los humanos, como la capacidad de memorizar y asociar hechos Huyan et al. (2019). El Perú es uno de los países de todo el mundo que se enfrenta a los problemas actuales con la gestión de la infraestructura y mantenimiento Benallal y Tayeb (2023). Dado que la infraestructura vial no es uno de los activos de mayor valor que posee el país y mantenerla llevará a un enorme efecto en la economía del país. En cuanto a la detección de características u objetos, la Industria 4.0 toma un lugar sumamente importante enfocados al monitoreo automático que suelen manejar las empresas, esto permite estar en contacto con infraestructura y sus daños por medio de visión artificial. Actualmente, existen técnicas de monitoreo basadas en imágenes para detectar los defectos o fallos en los edificios o puentes, además, capta fotografías y admira la idea real y visual de toda la escena Mohan y Poobal (2018). Sin embargo, no hacen función de esos nuevos métodos y utilizan la inspección visual, realizan una clasificación y segmentación de grietas, inspeccionan por líquidos penetrantes o incluso con métodos automatizados que no involucran la inteligencia artificial Kim et al. (2019). La solución requiere un clasificador que pueda discriminar las estructuras como dañadas o intactas basándose en una red neuronal artificial y así prevenir un mantenimiento a la edificación, de tal manera no esperar a que esta colapse u ocasiones algún daño en los ciudadanos Lee et al. (2013). La detección automática de grietas es muy efectiva para las pruebas no destructivas como pruebas infrarrojas y térmicas, pruebas ultrasónicas, pruebas con láser y pruebas con radiografías Moon y Kim (2011). Entonces, en base a lo mencionado, nos vemos en la necesidad de crear un algoritmo de visión artificial con redes neuronales que sea capaz de identificar, clasificar y medir las fisuras registradas en imágenes digitales Nehdi y Soliman (2012), permitiendo detectar con un dispositivo móvil en tiempo real las diferentes fisuras y/o patologías que se encuentren en las estructuras de concreto, de tal manera que se pueda recopilar datos y analizarlos Spencer et al. (2019). En general, para obtener la resolución con las características deseadas, se requiere un algoritmo de procesamiento de imágenes utilizando un sistema de ondas milimétricas y de microondas en estructuras Thatoi (2013), por lo que en el presente proyecto nos enfocaremos a realizar un algoritmo para detección de rajaduras en estructuras de concreto en general. Acotando que, se necesita de la ayuda de un sistema robótico como medio para alcanzar zonas específicas de la estructura, esto es importante para evitar fallos con el uso de Inteligencia Artificial Ortega (2021). Un estudio realizado sobre detección y reporte de fisuras mediante visión por computadora usando partículas magnéticas, relata que las fisuras en partes metálicas pueden fallar debido a fatiga o esfuerzos excesivos Ortiz (2015). Este problema puede atacar parte de nuestra problemática, teniendo en cuenta que existen partes de la infraestructura que está adherido a metales como soporte. Sin embargo, existen nuevas técnicas que mejoran la calidad de las imágenes, permitiendo enfocar solamente las fisuras y grietas que puedan

existir en las estructuras de concreto. El objetivo de esta investigación es desarrollar un algoritmo de visión artificial con redes neuronales que nos ayude a identificar fisuras en superficies de concreto, para así prevenir accidentes e incidentes a consecuencia del desgaste de las estructuras. Asimismo, planteamos tres puntos como objetivos específicos: diseñar un plan estratégico para detallar las actividades que se realizarán, definir conceptos en base al proyecto y realizar un análisis breve sobre los resultados.

Material y métodos:

El presente estudio es de carácter experimental, por ende, se hará uso de programaciones realizadas en Spyder 5.4.3. Además, se utilizaron otros materiales para el proyecto como: Laptop ASUS TUF GAMING, cámara de celular iphone 13, aplicación iVCam, un sujetador para el celular, lenguaje de programación Python, biblioteca opencv y una interfaz gráfica (Anaconda Navigator). Existen varios métodos para detectar fisuras o grietas en las estructuras de concreto, utilizando recursos proporcionados por la inteligencia artificial, como el aprendizaje automático y redes neuronales convolucionales.

Método 1. Red neuronal profunda (FCN)

El método consiste en la experimentación para evaluar la capacidad de clasificación de diferentes redes neuronales convolucionales (CNN) pre-entrenadas, llegando a escoger un modelo en específico que será la espina dorsal de la red neuronal completamente convolucional (FCN); la tarea del codificador consiste en procesar la imagen de entrada y extraer las características necesarias para su segmentación; mientras que las capas que actúan como decodificador se encargan de reconstruir la imagen segmentada, para obtener características de alta resolución Alarcon y Poma (2021).




Figura 1. Arquitectura de la red para la segmentación semántica.

Nos presenta la arquitectura del codificador y decodificador propuesta por el autor para la detección de fisuras en imágenes Copyright 2019 Dung y Anh. En la Figura 1 nos muestra como la segmentación semántica es una técnica utilizada en visión por computadora que tiene por objetivo dividir una imagen en regiones semánticas significativas. Las imágenes varían en sus acabados superficiales y condiciones de iluminación, y se utilizan para evaluar el método propuesto para la detección de fisuras. La clasificación de las diferentes redes neuronales entrega resultados mayores al 97%, quiere decir que se obtiene las características de las fisuras de alta calidad. Este método se basa en la experimentación y evaluación de diferentes redes neuronales convolucionales (CNN) pre-entrenadas para determinar su capacidad de clasificación. Una vez elegido un modelo específico, se utiliza como la espina dorsal de la red neuronal completamente convolucional (FCN). En el caso del modelo propuesto por Dung y Anh, se utilizan tres CNN previamente entrenadas, a saber: VGG16, Inception y ResNet, para actuar como codificadores de la FCN Pozzo (2020). La tarea del codificador es procesar la imagen de entrada y extraer las características necesarias para la segmentación, mientras que las capas del decodificador se encargan de reconstruir la imagen segmentada para obtener características de alta resolución.

Los autores informan que, en el proceso de entrenamiento, el modelo VGG16 y el Inception V3 lograron una precisión cercana al 99.9%, mientras que el modelo ResNet logró solo un 97.5% en la clasificación de imágenes. Durante la fase de experimentación, tanto el VGG16 como el Inception V3 lograron una clasificación casi perfecta, con solo 6 errores de falsos positivos o falsos negativos de un total de 4000

imágenes Pozzo (2020). Por otro lado, el modelo ResNet presentó 110 falsos positivos y 12 falsos negativos en la misma muestra.

Método 2. Identificación y segmentación de imágenes.

Método basado en el aprendizaje automático y la máquina de vectores soporte. Para probar la efectividad del método, se utilizaron seis vigas de hormigón y cuatro de hormigón armado en un ensayo de flexión, una placa de acero de 12 mm de espesor, un material compuesto que constaba de seis capas iguales de espuma de construcción (24 x 24 x 9 cm) y una placa de aluminio (15 x 6 x 1 cm) cubierta por una capa de goma Noori et al. (2019).




Figura 2. Identificación de fisuras en el concreto.

En la Figura 2 se puede observar la arquitectura de red para la segmentación semántica que se basa principalmente en redes neuronales convolucionales debido a su capacidad para capturar características locales y globales de una imagen.

La metodología propuesta para la detección de daños utiliza un clasificador discriminatorio llamado Máquina de Vectores de Soporte (SVM, por sus siglas en inglés), en el que un SVM tradicional proporciona información sin clasificar Noori et al. (2019). Los autores proponen una mejora utilizando una ecuación que encuentra y clasifica la información de manera adecuada, lo que lleva a una etapa de entrenamiento en la que los parámetros adquieren peso para la clasificación, normalizando los valores a 0 y 1 con sus respectivas etiquetas.

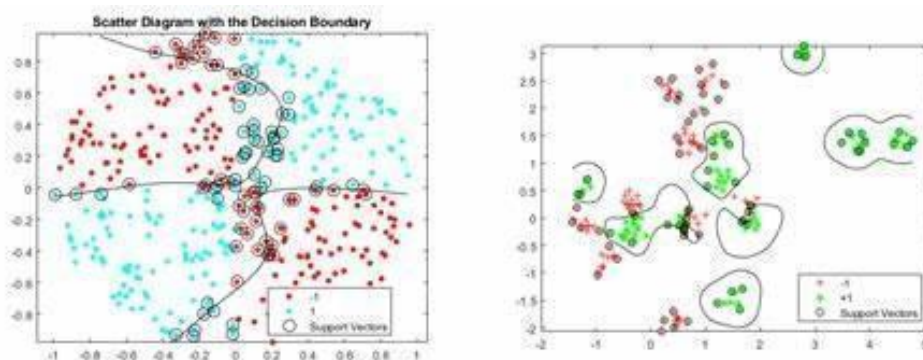


Figura 3. Máquina de Vectores de Soporte para la detección de daños.

En la Figura3 nos muestra la máquina de vectores de soporte que su objetivo en la detección de daños es encontrar el hiperplano que maximiza el margen entre las muestras de diferentes clases, lo que implica buscar la mayor separación posible entre los datos de “daños” y “sin daños”. Para visualizar y detectar las fisuras críticas se basan en que los cambios en la integridad estructural pueden ser reconocidos por las variaciones de la intensidad en diferentes intervalos, lo que resulta en una imagen

que se somete a un preproceso que convierte la imagen en escala de grises con intensidades que varían de 0 a 255 Noori et al. (2019). Luego se realiza una binarización de Otsu o una binarización tradicional, y se detectan los bordes de las fisuras. Los resultados mostraron que el análisis mediante SVM produjo una precisión del 87,22%, en comparación con el método tradicional que alcanzó el 84,72%.

Método 3. Aprendizaje profundo de clasificación

Se presentaron 851 imágenes de diferentes especímenes de hormigón, los cuales presentan distintos tipos de superficie. El método propone un proceso experimental de 4 fases: crear un conjunto de datos de imagen clasificada de referencia, establecer el punto de referencia para el sistema de inteligencia artificial, implementar el enfoque de transferencia de aprendizaje y realizar los experimentos de entrenamiento. En la primera fase se utilizan 851 imágenes de alta resolución que se reducen a 3500 muestras de 256 x 256 píxeles, clasificadas como fisuradas y no fisuradas, y se utiliza el 80% para el entrenamiento. En la segunda fase se utiliza la red neuronal convolucional VGG 16 para identificar fisuras en el hormigón, pero como la muestra de imágenes es pequeña se utiliza la metodología de transferencia de aprendizaje Silva y Lucena (2018). En la etapa de experimentación, se probaron diferentes valores de velocidad de aprendizaje, número de nodos en la capa conectada y tamaño del set de datos de entrenamiento, obteniendo el mejor resultado con un 92,27%, donde el tamaño del set de datos se identificó como la variable más importante.

Método 4. Aprendizaje profundo con uso de redes neuronales convolucionales.

En este método se utilizó una muestra de 332 imágenes tomadas de un complejo de edificios en la Universidad de Manitoba. De estas imágenes, 277 fueron utilizadas para el entrenamiento y 55 para la prueba del modelo. Las imágenes presentan una gran variación en cuanto a la iluminación, sombras y distancias Cifuentes (2021). Para la etapa de entrenamiento, las imágenes se dividieron en dos categorías: imágenes con fisuras y sin fisuras, determinando "fisura" cuando esta es discernible por el ojo humano. La metodología utilizó MatConvNet como la red neuronal profunda, con una arquitectura de 8 capas, de las cuales las capas L1, L3, L5 y L7 son convolucionales, L2 y L4 son capas de agrupamiento, la capa L6 es un rectificador lineal, y la última capa L8 determina si la imagen presenta una fisura o no. Para generar un clasificador de fisuras con el CNN, cada imagen se redujo en tamaño, obteniendo un total de 4000 muestras, y el CNN aprendió automáticamente características actualizando la ponderación de cada receptor.




Figura 4. Redes Neuronales para identificar fisuras.

En la Fig.4 nos muestra las redes neuronales para la identificación de fisuras son un tipo de modelo de aprendizaje profundo utilizado en visión por computadora. Estas redes se diseñan específicamente para detectar y clasificar fisuras en imágenes, como las imágenes de estructuras o superficies

Las redes neuronales tienen una etapa a seguir para detectar o no las fisuras en el concreto. Donde el 80% de las imágenes se utilizan para entrenarlas y el otro 20% para su validación. Por otro lado, también existen módulos de coeficientes, como el de Wavelet.

$$S_1x = U_1x * \theta_j \dots (1)$$

$$U_1x = (u, W_1)$$

$$= |x * \varphi_{w1}^1(u)| = \left| \sum_v x(u) \varphi_{w1}^1(u-v) \right| \dots (2)$$

Donde U_1x es el módulo de coeficientes Wavelet, θ_l es la función de escalamiento, y x la imagen de entrada Cifuentes (2021). Con el objetivo de mejorar el contraste y de resaltar características en la imagen; esta permite una imagen de menor tamaño y con los bordes resaltados. Como se observa en el cálculo (módulo de coeficientes Wavelet), se centra en utilizarla como técnica matemática para medir o analizar señales en diferentes escallas de tiempo y frecuencia. Las cuales, al momento de ser aplicadas, se obtienen una serie de frecuencias y tiempo.

Método 5. Tratamiento de imágenes.

En el presente estudio, las imágenes con grietas de pavimento asfáltico fueron captadas con un cámara de escaneo por una determinada área sostenida. Está cámara fue configurada con una resolución de 1920 x 1080 y representación de color RGB con profundidad de 8 bits; en la cual nos permite ajustar la configuración básica de las imágenes como (nitidez, saturación y el contraste), así mismo, se cuenta con un sensor tipo CMOS, que nos permite mejorar la sensibilidad, reducir el ruido y obtener imágenes con poca iluminación. La codificación empleada para generar el esqueleto u el sentido de las grietas transversales y longitudinales se muestra respectivamente, en el Fig. 5(a) y 4(b). los valores se generan aleatoriamente y se almacenan en un vector, la combinación de las codificaciones forma otro tipo de grietas con tamaños de 0,1 mm a 0,3mm y 0,1 a 2mm de lado respectivamente.




Figura 5. Codificación empleada para generar las grietas.

Donde:

(a) Codificación de grieta transversal.

La codificación de grietas transversales implica asignar un código o etiqueta específica para identificar las fisuras que se extienden perpendicularmente a la dirección principal o longitudinal de una estructura o superficie. Estas grietas se caracterizan por tener una orientación transversal o cortes perpendiculares a la dirección predominante.

(b) Codificación de grieta longitudinal.

La codificación de grietas longitudinales implica asignar un código o etiqueta específica para identificar las fisuras que se extienden paralelamente a la dirección principal o longitudinal de una estructura o superficie. Estas grietas se caracterizan por tener una orientación longitudinal o cortes paralelos a la dirección predominante.

La librería empleada fue Open CV versión 3.2, en la cual se brindan opciones en las cuales se permite la manipulación y captura de las imágenes Numpy 1.24.1, aplicativo el cual permite nombrar a un conjunto de funciones para realizar operaciones entre vectores y matrices, como convertir imágenes en unidimensionales o bidimensionales. Se elabora un píxel semilla el cual determinará el inicio de la grieta, luego mediante los valores del vector director se establece el sentido propuesto por el código de Freeman. El cual representa la grieta vertical y longitudinal tomando la precisión de 1mm/píxel. El algoritmo consiste en verter la intensidad de fondo en la constante A, el valor asignado tiene los niveles de grises que necesita la imagen. Aplicando tile partitioning, cada imagen es dividida en 120 x 120 píxeles (Gmi), el valor máximo (Gmaxi) y el valor mínimo (Gmini).

$$L_{sup,i} = G_{m,i} + (K)(G_{max,i} - G_{m,i}) \quad (1)$$

$$L_{inf,i} = G_{m,i} - (K)(G_{m,i} - G_{min,i}) \quad (2)$$

Por último, para realizar el algoritmo que detecte grietas o fisuras en el concreto se realizaron las siguientes funciones:

Tabla 1.

Funciones principales.

Función	Descripción
<code>gray = cv2.cvtColor(frame, cv2.COLOR_BGR2GRAY)</code>	Sirve para convertir la imagen a escala de grises.
<code>contours, hierarchy = cv2.findContours(edges, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)</code>	Buscar contornos en la imagen
<code>cv2.drawContours(frame, [contour], 0, (0, 255, 0), 2)</code> <code>cv2.putText(frame, "Grieta", (contour[0][0][0], contour[0][0][1]))</code> <code>cv2.FONT_HERSHEY_SIMPLEX, 1, (0, 0, 255), 2)</code>	Dibuja los contornos en la imagen original y detecta las grietas en el concreto

Resultados

Realizamos pruebas durante 4 semanas en distintos tipos de concreto: con grietas horizontales, verticales, diagonales, con huecos y en buen estado y estos fueron los resultados:

Tabla 2.

Resultados obtenidos de la examinación de las estructuras de concreto

	N° de estructuras de concreto	Grietas verticales		Grietas horizontales		Grietas diagonales		Huecos		Buen estado	
		Si detecta	No detecta	Si detecta	No detecta	Si detecta	No detecta	Si detecta	No detecta	Si detecta	No detecta
SEMANA 1	1	Si detecta									
	2			Si detecta							
	3					No detecta					
	4							No detecta			
	5									No detecta	
SEMANA 2	1	Si detecta									
	2			Si detecta							
	3					Si detecta					
	4							No detecta			
	5									No detecta	
SEMANA 3	1	Si detecta									
	2			Si detecta							
	3					Si detecta					
	4							No detecta			
	5									Si detecta	
SEMANA 4	1	Si detecta									
	2			Si detecta							
	3					Si detecta					
	4							Si detecta			
	5									Si detecta	

Los resultados obtenidos dentro de las cuatro semanas de pruebas estudiando las 5 estructuras de concreto conseguidas son:

- ✓ En la semana 1 obtuvimos ningún resultado, no obstante, el programa detectaba el contorno de las estructuras, esta semana

- ✓ En la semana 2 obtuvimos una mejora, ya que esta semana de pruebas el programa detecto grietas verticales, horizontales y diagonales, mas no los huecos y las estructuras en buen estado.
- ✓ En la semana 3 mejoro mucho con respecto a la anterior semana, debido a que esta semana logro captar las estructuras en buen estado
- ✓ En la última semana se obtuvo éxito en todas las pruebas realizadas en la detección de fisuras, patologías u otros desperfectos del concreto.

Imágenes recolectadas antes de las pruebas de detección de fisuras en el concreto.



Figura 6. Imagen antes de hacer las pruebas.

En las figuras 6 se muestra la imágenes antes de hacerse las pruebas con el sistema de detección de rajaduras en estructuras de concreto, con la cámara de un iphone 13 conectado por una aplicación (iVCam) que enlaza la cámara del celular con la programación de la computadora.

Imágenes recolectadas después de las pruebas de detección de fisuras en el concreto.




Figura 7. Detección de fisura en concreto

En la figura 7, se detectaron todo tipo de fisuras donde se demuestra que el sistema de detección de grietas en estructuras de concreto funciona. Dando resultados eficientes, sin embargo, detecta algunos contornos adicionales donde el algoritmo puede mejorar haciendo uso de las redes neuronales.

Porcentaje de Eficiencia

Realizamos más pruebas para determinar la eficiencia de nuestro código, realizamos 8 pruebas en distintos tipos e concreto para así poder determinar qué tan eficiente es nuestro código de detección de fisuras y patologías en el concreto.

Tabla 3.

Cuadro de resultados de eficiencia por intento

	Rajaduras detectadas	Rajaduras totales	Eficiencia
Intento 1	10	25	40.00%
Intento 2	6	11	54.55%
Intento 3	9	15	60.00%
Intento 4	10	15	66.67%
Intento 5	20	28	71.43%
Intento 6	5	7	71.43%
Intento 7	4	5	80.00%
Intento 8	8	10	80.00%
Intento 9	6	7	85.71%
Intento 10	36	39	92.31%
Intento 11	10	11	90.91%
Intento 12	23	24	95.83%

Como se observa en la tabla, conforme suben los intentos, el sistema de detección con vision artificial para las fisuras en el concreto se acerca cada vez más al número de rajaduras totales. Teniendo en cuenta que se utilizó la formula siguiente para la eficiencia. En los últimos intentos para la detección de fisuras o rajaduras en el concreto pasaba del 90%, donde se demuestra que el aprendizaje de las redes neuronales en el algoritmo del proyecto.

Tabla 4.

Cuadro de eficiencia por semana

Semana	Eficiencia (%)
Semana 1	51.52
Semana 2	69.84
Semana 3	81.90
Semana 4	93.02

Como se observa en la Tabla 4, se puede determinar que, hubo una mejora de 41,50% de mejora con respecto a la semana 1 y semana 4. Lo cual es un porcentaje positivo para nuestra investigación.




Figura 8. Total de eficiencia (semana)

En el gráfico se observa que, en la última semana, después de varios intentos realizados, muestra que la eficiencia total del proyecto “Desarrollo de un algoritmo de visión artificial con redes neuronales para la detección de fisuras en estructuras de concreto” es de 93,02%. Determinando que el algoritmo creado puede ir aumentando la detección de fisuras mientras se implemente más redes neuronales y otros métodos, subiendo la eficiencia hasta llegar a un 100%.

Discusión

El estudio titulado "Detección de fisuras en concreto basada en clasificación de imágenes mediante aprendizaje profundo" arrojó un resultado promedio de eficiencia del 92,27% en todas sus pruebas realizadas para la detección de fisuras en estructuras de concreto. No obstante, en nuestro propio proyecto de investigación logramos alcanzar un promedio de eficiencia del 93,02%. ¿Cómo lo conseguimos? Utilizamos el programa IV Cam, que nos permite conectar una cámara de mayor calidad, específicamente la del iPhone 13. Al emplear esta cámara de alta calidad, obtuvimos imágenes con una mayor resolución y nitidez, lo cual nos permitió mejorar significativamente la precisión en la detección de fisuras, huecos, patologías y otros desperfectos presentes en las estructuras de concreto estudiadas. Esta mejora en la calidad de imagen nos brindó una ventaja en la identificación y análisis de los defectos, lo cual se tradujo en un promedio de eficiencia del 93,02% en nuestras pruebas. Esto implica que nuestro enfoque superó al del estudio de referencia, demostrando su viabilidad y destacando la importancia de utilizar tecnología avanzada para mejorar la precisión en la detección de problemas en el concreto

Conclusiones

Después de la implementación y uso de las fórmulas y métodos mencionados anteriormente. Concluimos que el proyecto si es eficiente, el algoritmo de visión artificial mientras más datos específicos, con un porcentaje de 93.02% detectando grietas en estructuras de concreto.

Se concluyó el trabajo de los datos obtenidos en la semana 4 donde se detectó huecos en la estructura de concreto, llevándonos a la conclusión que nuestro proyecto si es eficiente.

Los resultados obtenidos en nuestro proyecto ayudaran a todas las empresas constructoras a detectar rajaduras, huecos en los concretos para que de esta manera puedan ser reparadas y puedan durar un tiempo más, y evite desastres.

Referencias

- Alarcon Carpio, J. C., & Poma Astete, R. F. (2021). Desarrollo de un algoritmo computacional de detección de equipos de protección eléctrica en personas, orientado a sistemas de vigilancia basados en cámaras IP. <http://hdl.handle.net/10757/657930>
- Benallal, M. A., & Tayeb, M. S. (2023). An image-based convolutional neural network system for road defects detection. *IAES International Journal of Artificial Intelligence*, 12(2), 577.
- Cifuentes, L. V. T., Marulanda, J., & Thomson, P. (2021). Detección de grietas en el pavimento usando técnicas de procesamiento de imágenes y redes neuronales artificiales. *Encuentro Internacional de Educación en Ingeniería*. <https://acofipapers.org>
- Dung, C. V. (2019). Autonomous concrete crack detection using deep fully convolutional neural network. *Automation in Construction*, 99, 52-58.
- Huyan, J., Li, W., Tighe, S., Zhai, J., Xu, Z., & Chen, Y. (2019). Detection of sealed and unsealed cracks with complex backgrounds using deep convolutional neural network. *Automation in Construction*, 107, 102946.
- Kim, H., Ahn, E., Shin, M., & Sim, S. H. (2019). Crack and noncrack classification from concrete surface images using machine learning. *Structural Health Monitoring*, 18(3), 725-738.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Lee, B. Y., Kim, Y. Y., Yi, S. T., & Kim, J. K. (2013). Automated image processing technique for detecting and analysing concrete surface cracks. *Structure and Infrastructure Engineering*, 9(6), 567–577. <https://doi.org/10.1080/15732479.2011.593891>
- Meléndez, R. P., Herrera, A., Pérez, J. L., & Padrón-Gómez, A. (2000). El modelo neuronal de McCulloch y Pitts. *Interpretación Comparativa del Modelo XV CONGRESO NACIONAL DE INSTRUMENTACIÓN, Guadalajara Jalisco, México*.
- Mohan, A., & Poobal, S. (2018). Crack detection using image processing: A critical review and analysis. *alexandria engineering journal*, 57(2), 787-798. <https://doi.org/10.1016/j.aej.2017.01.020>
- Moon, H. G., & Kim, J. H. (2011). Intelligent crack detecting algorithm on the concrete crack image using neural network. *Proceedings of the 28th International Symposium on Automation and Robotics in Construction, ISARC 2011*, 1461–1467. <https://doi.org/10.22260/isarc2011/0279>
- Nehdi, M. L., & Soliman, A. M. (2012). Artificial Intelligence Model for Early-Age Autogenous Shrinkage of Concrete. *ACI Materials Journal*, 109(3), 353–362. <https://doi.org/10.14359/51683826>
- Noori Hoshyar, A., Rashidi, M., Liyanapathirana, R., & Samali, B. (2019). Algorithm development for the non-destructive testing of structural damage. *Applied Sciences*, 9(14). <https://doi.org/10.3390/app9142810>
- Ortega Triana, J. A. (2021). Aprendizaje profundo para la detección automática de fisuras de hormigón usando redes neuronales convolucionales. <http://hdl.handle.net/10251/174954>
- Ortiz Castillo, J. (2015). Sistema de visión artificial humanoide para reconocimiento de formas y patrones de objetos, aplicando redes neuronales y algoritmos de aprendizaje automático. <https://hdl.handle.net/20.500.14138/2010>
- Pozzo, M. H. C. (2020). *Uso de inteligencia artificial para la detección automatizada de fisuras en estructuras de hormigón armado* (Doctoral dissertation, Pontificia Universidad Católica de Chile (Chile)).
- Silva, W. R. L. D., & Lucena, D. S. D. (2018). Concrete cracks detection based on deep learning image classification. In *Proceedings* (Vol. 2, No. 8, p. 489). MDPI. <https://doi.org/10.3390/icem18-05387>

Spencer, B. F., Hoskere, V., & Narazaki, Y. (2019). Advances in Computer Vision-Based Civil Infrastructure Inspection and Monitoring. *Engineering*, 5(2), 199–222. <https://doi.org/10.1016/j.eng.2018.11.030>

Thatoi, D. N. (2013). Application of Artificial Intelligence Techniques for Detection of Cracks-A Review. *International Journal of Engineering and Technology*, 5(1), 57–59. <https://doi.org/10.7763/ijet.2013.v5.510>