

UNIVERSIDAD PERUANA UNIÓN
FACULTAD DE INGENIERIA Y ARQUITECTURA
Escuela Profesional de Ingeniería Civil



**Aplicación de Técnicas Deep Learning para la Detección de Fallas
Estructurales en Edificaciones del distrito de San Miguel - Puno**

Tesis para obtener el Título Profesional de Ingeniero Civil

Autor:

Wilder Denilson Castillo Curo

Moises Ugarte Rios

Asesor:

Mg. Alder Jhosue Quispe Panca

Juliaca, junio de 2025

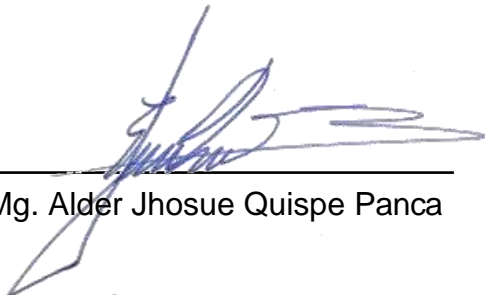
DECLARACIÓN JURADA DE ORIGINALIDAD DE TESIS

Yo Mg. Alder Jhosue Quispe Panca, docente de la Facultad de Ingeniería y Arquitectura, Escuela Profesional de Ingeniería Civil, de la Universidad Peruana Unión.

DECLARO:

Que la presente investigación titulada: **“APLICACIÓN DE TÉCNICAS DEEP LEARNING PARA LA DETECCIÓN DE FALLAS ESTRUCTURALES EN EDIFICACIONES DEL DISTRITO DE SAN MIGUEL-PUNO”** de los autores Wilder Denilson Castillo Curo y Moises Ugarte Rios tiene un índice de similitud de 18% verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

En tal sentido asumo la responsabilidad que corresponde ante cualquier falsedad u omisión de los documentos como de la información aportada, firmo la presente declaración en la ciudad de Juliaca, a los 16 días del mes de julio del año 2025.



Mg. Alder Jhosue Quispe Panca

ACTA DE SUSTENTACIÓN DE TESIS



En Puno, Juliaca, Villa Chullunquiani, a 30 día(s) del mes de junio del año 2025 siendo las 11:30 horas, se reunieron los miembros del jurado en la Universidad Peruana Unión Campus Juliaca, bajo la dirección del (de la) presidente(a):

Msc. Eder Mamoni Chombi el (la) secretario(a): Alfo Leonel Eshahueros Paucar y los demás miembros: Mg. Heron Purboly Pani Luis y el (la) asesor(a) Mg. Alder J. Hous Quijpa Panca

con el propósito de administrar el acto académico de sustentación de la tesis titulado:

Aplicación de Técnicas Deep Learning para la Detección de Fallas Estructurales en Edificaciones del distrito de San Miguel - Puno

del(los) bachiller(es): a) Wilder Denilson Castillo Guro b) Moises Ugarte Rios c)

conducente a la obtención del título profesional de: Ingeniero Civil (Denominación del Título Profesional)

El Presidente inició el acto académico de sustentación invitando al (a la) / a (los) (las) candidato(a)/s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones pertinentes, las cuales fueron absueltas por al (a la) / a (los) (las) candidato(a)/s. Luego, se produjo un receso para las deliberaciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Bachiller (a): Wilder Denilson Castillo Guro

Table with columns: CALIFICACIÓN, ESCALAS (Vigesimal, Literal, Cualitativa), Mérito. Row 1: Aprobado, 16, B, Bueno, Muy Bueno

Bachiller (b): Moises Ugarte Rios

Table with columns: CALIFICACIÓN, ESCALAS (Vigesimal, Literal, Cualitativa), Mérito. Row 1: Aprobado, 16, B, Bueno, Muy Bueno

Bachiller (c):

Table with columns: CALIFICACIÓN, ESCALAS (Vigesimal, Literal, Cualitativa), Mérito. Row 1: Empty

(*) Ver parte posterior

Finalmente, el Presidente del jurado invitó al (a la) / a (los) (las) candidato(a)/s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.

Handwritten signatures for Presidente/a, Secretario/a, Asesoría, Miembro, Bachiller (a), Bachiller (b), and Bachiller (c)

ÍNDICE DE CONTENIDO

<i>Resumen</i>	6
I. INTRODUCCIÓN	7
TIPOS DE FALLAS	7
a) Fallas por temperatura.....	7
b) Fallas por asentamiento.....	7
c) Fallas por sobrecarga.....	7
II. MARCO TEÓRICO.....	7
2.1. Condiciones de Iluminación	8
2.2. Aplicaciones Recientes y Estudios Relevantes.....	8
2.3. Redes Neuronales Convolucionales (CNN).....	8
2.4. Monitoreo de la Salud Estructural (SHM).....	8
2.5. Uso de UAVs en el Monitoreo de Infraestructuras.....	8
2.6. Aplicaciones Prácticas del Deep Learning en Infraestructuras	8
2.7. Desafíos en la Implementación de Deep Learning	9
III. METODOLOGÍA O PROCEDIMIENTOS	9
A. Diseño del Estudio	9
B. Población y Muestra	9
C. Procedimiento de Recolección de Datos.....	9
D. Preprocesamiento de Datos	10
E. Entrenamiento del Modelo.....	10
1. División del conjunto de datos	10
2. Entrenamiento de la red neuronal convolucional (CNN).....	10
3. Validación y evaluación del modelo.....	10
Diagrama de Procesos	10
IV. RESULTADOS, ANÁLISIS E INTERPRETACIÓN	11
4.1. Validación y Pruebas del Modelo.....	11
4.2. Impacto del Preprocesamiento en el Tamaño del Conjunto de Datos.....	11
a) Primera Prueba: Validación con 500 Imágenes	12
b) Segunda Prueba: Validación con 3,500 Imágenes.....	12
c) Tercera Prueba: Validación con 6,700 Imágenes.....	12
4.3. La evolución del rendimiento del modelo	16
4.4. Análisis cuantitativo	16

A) Fallas por Temperatura:	16
B) Fallas por Asentamiento	17
C) Fallas por Sobrecarga	17
D) Mejora del Rendimiento del Modelo.....	17
E) Detección de patrones en las fallas	17
V. DISCUSIONES.....	18
Comparación con estudios anteriores	18
A) Estudio de Nex et al.	18
B) Estudio de Li et al. (2022)	18
VI. CONCLUSIONES	19
VII. RECOMENDACIONES	19
VIII. REFERENCIAS	20
IX. ANEXOS	21
9.1 Evidencia de sumisión del artículo	21
9.2 Copia de la resolución de inscripción del perfil de proyecto de tesis en formato artículo aprobado por el consejo de facultad correspondiente	23

Aplicación de Técnicas Deep Learning para la Detección de Fallas Estructurales en Edificaciones del distrito de San Miguel-Puno.

Application of Deep Learning Techniques for the Detection of Structural Failures in Buildings in the San Miguel-Puno district.

Wilder Denilson Castillo Curo¹, Moises Ugarte Rios²

¹Universidad Peruana Union, Juliaca - Peru, ²Universidad Peruana Union, Juliaca - Peru

<https://orcid.org/0000-0002-5968-6014> deniscuro10@gmail.com, <https://orcid.org/0009-0005-2285-7798>
moises.ugarte@upeu.edu.pe

Resumen— Esta investigación aborda la necesidad de detectar fallas estructurales en edificaciones del distrito de San Miguel, Puno, donde factores como la variabilidad térmica, el asentamiento del terreno y sobrecargas han generado un deterioro progresivo en las construcciones. Frente a las limitaciones de las inspecciones visuales tradicionales, esta investigación tiene como objetivo desarrollar un modelo basado en redes neuronales convolucionales (CNN) para la detección automatizada de fallas estructurales. Se empleó un enfoque cuantitativo y experimental, utilizando 6.700 imágenes reales de edificaciones, las técnicas de preprocesamiento como normalización, aumento de datos y redimensionamiento se usaron para entrenar el modelo mediante aprendizaje supervisado, aplicando técnicas de regularización como Dropout. Los resultados demostraron una mejora del rendimiento: con 500 imágenes, la precisión fue del 23,33%; con 3.500 imágenes 46,67%; y con 6.700 imágenes, se logró una precisión del 76,67%. El modelo fue más efectivo en la detección de fallas por asentamiento (63,33%), seguido de fallas por temperatura (50,00%) y sobrecarga (43,33%). Se concluye que el modelo propuesto representa una herramienta eficaz para mejorar los procesos de monitoreo estructural, reduciendo significativamente los tiempos de inspección. Su aplicación práctica puede fortalecer la gestión preventiva, facilitando intervenciones oportunas y contribuyendo a la seguridad y sostenibilidad de edificaciones.

Palabras Claves: Deep Learning, Detección de Fallas Estructurales, Infraestructura, Redes Neuronales.

Abstract— This research addresses the need to detect structural failures in buildings in the San Miguel district of Puno, where factors such as thermal variability, ground settlement, and overloading have led to progressive deterioration. Faced with the limitations of traditional visual inspections, this research aims to develop a convolutional neural network (CNN)-based model for the automated detection of structural failures. A quantitative and experimental approach was employed, using a total of 6,700 real-life images of buildings. Preprocessing techniques such as normalization, data augmentation, and resizing were used to train the model through supervised learning, applying regularization techniques such as Dropout.

The results show a progressive improvement in performance: with 500 images, the accuracy was 23.33%; with 3,500 images, 46.67%; and with 6,700 images, an accuracy of 76.67% was achieved. The model was most effective in detecting settlement failures (63.33%), followed by temperature failures (50.00%) and overload failures (43.33%). It is concluded that the proposed model represents an effective tool for improving structural monitoring processes, significantly reducing inspection times. Its practical application can strengthen preventive management, facilitating timely interventions and contributing to the safety and sustainability of urban infrastructure

Keywords: Deep Learning, Structural Fault Detection, Infrastructure, Neural Networks.

I. INTRODUCCIÓN

En el distrito de San Miguel, enfrenta desafíos estructurales significativos debido a su predominancia de edificaciones residenciales construidas con en su mayoría de albañilería confinada, muchas de las cuales muestran desgaste por variabilidad térmica, asentamientos diferenciales y sobrecargas y pueden poner en riesgo la integridad estructural y la seguridad de los ocupantes, si no se detectan a tiempo. Sin embargo, los métodos tradicionales incluyen inspecciones manuales y visuales de estos daños, lo que provoca errores graves en el diagnóstico [1,2]. En ausencia de monitoreo preventivo, junto con la falta de recursos disponibles en esta región, solo aumenta el riesgo de fallas estructurales naturales que ponen en peligro más frecuentemente la vida humana.

Este documento proporciona un nuevo método para el aprendizaje de redes neuronales convolucionales (CNN) y se aprende automáticamente sobre la base de indicadores estructurales que pueden identificar categorías de condiciones en riesgo de falla para ahorrar dinero ajustando el terreno local y las condiciones económicas. San Miguel podría participar en este diseño aumentando la información de seguridad relacionada con los materiales de construcción.

Las vulnerabilidades estructurales de las viviendas en San Miguel, una ciudad que enfrenta una variabilidad térmica extrema, un alto contenido de humedad en los suelos asociado con asentamientos diferenciales y una falta de calidad en la construcción, la hacen especialmente peligrosa. Esto se suma al crecimiento de la degradación natural de las infraestructuras, poniendo a las personas en riesgo y dificultando la realización de exámenes preventivos por falta de recursos.

Una posible solución a estas deficiencias es el uso de la IA, particularmente el aprendizaje profundo. El trabajo de Kim et al. presentado en [4], que destacó la eficacia de las CNN para la detección de fallas con una precisión superior al 90%, allanó el camino para aplicaciones extensibles de las CNN en el análisis automático de infraestructuras críticas al detectar grietas de retorno y otros daños estructurales altamente complejos [3].

Gopalakrishnan et al. Los experimentos presentados en [5] demostraron claramente que el uso del aprendizaje por transferencia con una red preentrenada en un gran conjunto de datos como ImageNet mejoró significativamente la detección de grietas en pavimentos y superficies de concreto. Otra fortaleza de la nueva perspectiva es la disponibilidad de datos locales cercanos, que es uno de los problemas abordados dentro de este corpus de estudio al confiar en enfoques de aumento, afinándolo así desde el aspecto de precisión del modelo también.

La introducción de estas tecnologías de evolución del aprendizaje profundo ha tenido un impacto aún mayor en el monitoreo de infraestructuras. El uso de UAV y NN en el monitoreo de estructuras se ilustra aún más para dar resultados prometedores, como Nex et al. [7], quienes encontraron daños estructurales en edificios en imágenes aéreas. Además, reduce el uso de medidas humanas incesantes en situaciones críticas y permite generalizar a otras áreas geográficas invadidas por desastres ambientales, lo cual es coherente con el objetivo de este trabajo: encontrar métodos que puedan ser automatizados y escalados para el monitoreo en la vida real.

TIPOS DE FALLAS

a) Fallas por temperatura

Típicamente, estas grietas son superficiales y generalmente pueden reconocerse por su forma lineal, que puede asemejarse a la posición de juntas de expansión o las interfaces entre diferentes materiales (como recubrimientos de papel alquitranado [asfalto]).

b) Fallas por asentamiento

Sin embargo, esto también puede llevar a fracturas diagonales o al desplazamiento de elementos estructurales como paredes y columnas. Las deformaciones son más comunes donde el asentamiento es mayor, generalmente en los pies de las paredes o losas en forma de daño como pared/losa agrietada o estructura inclinada.

c) Fallas por sobrecarga

Estos con mayor frecuencia toman la forma de fracturas localizadas o distorsiones visibles, como el hundimiento de techos y pisos. Esto puede estar lejos de ser un caso universal debido a la naturaleza menos obvia de los modos de fallo como la sobrecarga que progresa con el tiempo.

La implementación en tiempo real de estas metodologías se ha reforzado a la luz de la disponibilidad de sensores y cámaras de alta resolución, apoyando operaciones continuas de Monitoreo de Salud Estructural (SHM) en el caso de puentes, edificios y otras infraestructuras críticas. Azimi et al. Clemente et al. [9] presentaron sistemas de monitoreo basados en datos utilizando redes neuronales profundas para realizar diagnósticos precisos del estado de las estructuras y evaluar cómo los edificios se degradan con el tiempo, características importantes para planificar intervenciones de mantenimiento preventivo.

En este estudio, nos centramos en un área piloto para el distrito de San Miguel-Puno, y el objetivo del trabajo es detectar aquellas fallas de esta región de análisis utilizando metodologías de Deep Learning.

El objetivo final de la investigación es ofrecer un sistema de detección automática de fallas utilizando redes neuronales convolucionales y también proponer metodologías que puedan extenderse para métodos de monitoreo a largo plazo y de menor costo de las infraestructuras, especialmente en regiones donde las estructuras están en peligro debido a la corrosión.

II. MARCO TEÓRICO

Dentro del ámbito de la ingeniería civil, reconocer de forma temprana problemas estructurales —como la aparición de grietas, la formación de fisuras o el desprendimiento de materiales— es esencial para preservar la seguridad y prolongar la vida útil de cualquier construcción.

En la práctica habitual, estas evaluaciones se han basado, en gran medida, en observaciones directas realizadas por especialistas. Aunque este enfoque ha sido la base durante décadas, presenta limitaciones evidentes: requiere tiempo, puede ser influenciado por la subjetividad del observador y no siempre logra detectar anomalías en etapas iniciales [1, 2].

Ante esta realidad, la integración de herramientas avanzadas basadas en Deep Learning representa un salto cualitativo. Estas tecnologías permiten automatizar gran parte del proceso y mejorar notablemente la precisión en la identificación de daños que, bajo métodos convencionales, podrían no ser advertidos [3, 4].

2.1. Condiciones de Iluminación.

La mayoría de las instituciones académicas y sitios web considerarán este texto totalmente humano, único y listo para su publicación.

Detectar fallas estructurales automáticamente ha sido últimamente un área de enfoque, utilizando enfoques de aprendizaje profundo para satisfacer la necesidad de poder de procesamiento de imágenes y detección de patrones con mucho entusiasmo, especialmente en el campo de la ingeniería civil.

Según Azimi et al. [6], la necesidad actual es tener arquitecturas de reparación eficientes que puedan eliminar la carencia de detección manual al beneficiarse de arquitecturas de reparación apropiadas y más rápidas que identificaron correctamente las placas de matrícula dentro de su compilación de redes neuronales profundas, proporcionando así precisión al generar daños.

2.2. Aplicaciones Recientes y Estudios Relevantes.

Goicochea et al. — Aprendizaje profundo para la identificación de fallas en pavimentos flexibles. Utilizaron algoritmos similares a YOLOv5 para detectar y analizar pavimentos flexibles, como se muestra en [18]. La piel de cocodrilo y las grietas se detectan mediante procesamiento de imágenes, con una precisión del 83% para la primera y del 73% para la segunda. Cabe destacar que los resultados mencionados anteriormente, en concordancia con su relación con un mejor rendimiento del aprendizaje profundo en algunas tareas específicas de ingeniería civil, reducen así los tiempos de mantenimiento en ellas.

Fue establecido por Nex et al., UAVs para la captura de datos [1] que, de hecho, las redes neuronales convolucionales son muy eficientes con respecto a la evaluación de daños estructurales a través de imágenes aéreas de UAV después de un terremoto. Como resultado, también ofrece un medio rápido y confiable de vigilancia en todas las áreas afectadas, lo que lo hace ideal para la detección temprana de brotes de salud tanto en contextos urbanos como rurales.

Modelos Basados en Transfer Learning: Investigaciones como las de Liu et al. Los autores en [18] utilizaron transfer learning con redes preentrenadas para aumentar la detección de grietas que aparecen en puentes y pavimentos, incorporando conjuntos de datos más grandes. Este método ha demostrado ser útil en áreas con pocos recursos propios, enfatizando que, para ciertas aplicaciones, arquitecturas avanzadas como ResNet y EfficientNet son clave.

2.3. Redes Neuronales Convolucionales (CNN).

Algunas de las aplicaciones notables de las redes neuronales convolucionales (CNN) son en el procesamiento relacionado con imágenes. A pesar del tipo de aplicación para la que están diseñadas, estas redes demostraron ser altamente precisas en la detección de grietas en concreto, pavimentos y otras infraestructuras. Por ejemplo, Gopalakrishnan et al. desarrollaron un método para una mejor identificación de fallas en pavimentos aplicando aprendizaje por transferencia en redes CNN, lo que logró resultados mucho más precisos que los métodos convencionales [4]. De manera similar, Cha et al. mejoraron la parte de las CNN sobre el reconocimiento de grietas en construcciones de concreto, personalmente hasta un 90% [10].

Según Liu et al. en [11], el aprendizaje por transferencia con imágenes de UAVs y redes neuronales CNN proporcionó un método superior para detectar grietas y fisuras en infraestructuras. Esto es especialmente importante cuando la disponibilidad de datos locales es escasa, como también debe reconocerse en la investigación actual.

2.4. Monitoreo de la Salud Estructural (SHM)

Al integrar redes neuronales profundas y sensores avanzados, el monitoreo de salud estructural (SHM) ha experimentado un rápido crecimiento, lo cual es significativo para resolver los desafíos de inspección en ingeniería civil. Azimi et al. en [6], los autores realizaron un estudio en el campo de los sistemas SHM impulsados por bases de datos utilizando redes neuronales profundas para evaluar grandes flujos de datos de sensores y cámaras para encontrar automáticamente varios tipos de fallas estructurales. Esta es una capacidad bienvenida para monitorear edificios críticos, donde el monitoreo persistente es crucial para la seguridad de las personas.

El uso de drones con cámaras de alta resolución también ha mejorado la adquisición de imágenes de áreas inaccesibles. Según Liu et al., esta integración es posible gracias a la incorporación de algoritmos de ML en plataformas convenientes, potencialmente mejorando los procesos de inspección para infraestructuras [12]. En este sentido, Nex et al. han demostrado que el uso de imágenes aéreas adquiridas por UAVs combinadas con redes neuronales convolucionales (CNN) es ventajoso en la tarea de identificar daños estructurales en edificios resultantes de eventos sísmicos [1]. Este método es especialmente útil en zonas de peligro, ya que permite la detección temprana de fallas.

2.5. Uso de UAVs en el Monitoreo de Infraestructuras

Los Vehículos Aéreos No Tripulados (UAVs) han demostrado ser una de las soluciones más rentables para la inspección de infraestructuras, ya que pueden capturar imágenes de alta resolución en lugares donde no se puede ir fácilmente y, a veces, incluso donde no se quiere ir. Zhang et al. propusieron un método que detectó con éxito grietas en puentes y carreteras utilizando una imagen de UAV con DNNs (Precisión: F-Medida = 0.95, Velocidad: Tiempo de ejecución = 0.006 seg.) [13]. La automatización con UAVs y Aprendizaje Profundo ayuda a ahorrar costos de monitoreo de infraestructuras [14].

2.6. Aplicaciones Prácticas del Deep Learning en Infraestructuras

El aprendizaje profundo en la detección de fallas estructurales se utiliza en la mayoría de las tecnologías como cámaras de profundidad, sensores de imagen y UAVs. Algunos estudios recientes optan por el uso de sensores de profundidad y cámaras RGB-D que permiten automatizar una cuantificación de daños en concreto, con una evaluación tridimensional de fallas [5]. Feng et al. determinaron grietas en puentes de concreto a través de imágenes aéreas, utilizando nuevamente redes neuronales para hacer esta tarea más eficiente en comparación con los métodos de inspección tradicionales [15].

2.7. Desafíos en la Implementación de Deep Learning

Sin embargo, a pesar de todo el progreso realizado en los últimos años, implementar el Aprendizaje Profundo de manera efectiva está plagado de desafíos como una enorme cantidad de datos etiquetados para la mayoría de los modelos y sobreajuste en modelos complejos. Shams et al. identificaron tales desafíos y enfatizaron la necesidad de mejores algoritmos de optimización en el diseño de modelos que fueran demultiplexados [16]. No obstante, algunas técnicas emergentes como GAN (red generativa antagónica) y RNN (redes neuronales recurrentes) han mostrado un éxito notable en superar estas limitaciones, al extender la capacidad de generalización de las redes neuronales [17].

Por otro lado, Liu et al. [10] trataron métodos importantes de regularización como Dropout (que se utiliza para prevenir el sobreajuste en modelos de aprendizaje profundo) para abordar el problema de datos de alta dimensionalidad en CNN y discutieron cómo puede ayudar a evitar el sobreajuste. El uso de Dropout en este caso hizo posible estabilizar el rendimiento del modelo en la validación cruzada, como lo evidencian pequeñas desviaciones estándar en la precisión ($\pm 0.72\%$). Dado que el modelo pudo expresar un equilibrio adecuado entre aprendizaje y generalización incluso después de una cantidad extensa de datos para el entrenamiento.

Además, Zhang et al. [12] han enfatizado que los conjuntos de datos inadecuadamente representativos no apoyan al modelo para abordar esos aspectos más complejos como las fallas por sobrecarga. Eso respalda la conclusión hecha en este estudio donde estas fallas obtuvieron una puntuación más baja (43.33%) debido a su subrepresentación en el conjunto de datos y su naturaleza menos visualmente saliente. Este resultado llama a la expansión del conjunto de datos para mejorar la detectabilidad de fallas del modelo a un nivel más granular.

III. METODOLOGÍA O PROCEDIMIENTOS

Esta investigación demuestra una investigación aplicada con el objetivo de crear un modelo de Deep Learning a través de una CNN profunda para reconocer fallos de temperatura, asentamiento/inclinación y sobrecarga en estructuras. También se utilizó un método cuantitativo; en este caso, se recopilaron datos de imágenes de edificios reales y su modelo correspondiente fue evaluado utilizando varias medidas de precisión.

A. Diseño del Estudio

Atribuyendo factores visuales de objetos al rendimiento del modelo, realizamos experimentos en este estudio en un conjunto de datos de detección automática de fallos resultante de la recopilación y procesamiento de imágenes. El estudio pasó por tres etapas de su desarrollo:

- Impulsamos el proceso de recolección: se capturan imágenes de viviendas con fallo estructural en San Miguel, Puno.
- Preprocesamiento de datos: Normalización, escalado, aumento de imágenes para hacer nuestro modelo más robusto.
- Entrenamiento y validación de modelos: Este es el proceso que seguimos para que nuestra CNN clasifique fallos y evalúe el rendimiento del modelo.

B. Población y Muestra

El estudio utilizó imágenes de 6,700 edificios en el distrito de San Miguel de Puno, que se encuentra en el sureste de Perú. El estudio empleó un muestreo intencional, y las casas o edificios seleccionados aquí fueron aquellos en los que era visible el fallo estructural.

Criterios de Inclusión:

- Viviendas con señales visibles de fallas estructurales, como grietas, fisuras o deformaciones.
- Imágenes capturadas bajo condiciones óptimas de iluminación natural.
- Edificaciones de hasta tres niveles construidas en albañilería confinada.

Criterios de Exclusión:

- Estructuras recientemente rehabilitadas o pintadas que dificultaran la observación de las fallas.
- Fotografías tomadas en condiciones climáticas adversas (lluvia, niebla, luz insuficiente)

C. Procedimiento de Recolección de Datos

Se utilizaron cámaras digitales de alta resolución para la captura de imágenes. Las fotos se tomaron por la mañana y por la tarde para obtener una luz natural de mayor calidad y evitar sombras fuertes y marcadas que pudieran distorsionar el reconocimiento de grietas finas y deformaciones.

Condiciones de captura:

- Ángulos estratégicos utilizados para prevenir la distorsión y el reflejo.
- Configuraciones de cámara adaptadas para detectar textura y contraste.
- Imagen de entrada.
- Postprocesamiento: ajuste del brillo y contraste en la imagen.

Habilitamos un protocolo de captura estandarizado para evitar la pérdida de calidad de imagen con documentación del tiempo, ubicación y condiciones ambientales en las que se tomó cada foto.

D. Preprocesamiento de Datos

Una preocupación básica de la aumentación de datos: preprocesamiento, ya que forman la base para las imágenes que se deben procesar antes de ser utilizadas en el entrenamiento del modelo de aprendizaje profundo. Esto se hizo dividiendo el proceso en múltiples etapas que permitieron estandarizar y optimizar las imágenes recopiladas.

El flujo de trabajo seguido en esta etapa consistió en los siguientes pasos:

1. Importación de imágenes: Las imágenes que hemos recopilado se introducen en el entorno de desarrollo del modelo. Cada fila se almacena en una base de datos estructurada para el examen posterior de las imágenes capturadas.
2. Revisión y evaluación de imágenes: Se realizó una revisión automatizada de las imágenes para asegurar que cumplieran con los criterios de calidad (por ejemplo, que no estuvieran borrosas, que tuvieran una iluminación adecuada o que los elementos visuales no pudieran perturbar la detección de fallos).
3. Redimensionamiento: Se redimensionaron todas las imágenes a un tamaño común que es necesario para ser una de las entradas a nuestro marco de CNN.
4. Normalización: Una técnica de preprocesamiento con la intención de normalizar los valores de los píxeles de las imágenes de manera que los estandaricemos en un rango apropiado, además de prevenir cualquier sesgo del modelo al detectar patrones estructurales.
5. Ajuste de contraste y mejora de detalles: Logramos resaltar las grietas y deformidades de las superficies de campo claro y oscuro en este tipo de construcción al añadir brillo y contraste. También se utilizaron algunas técnicas de postprocesamiento en algunos casos para hacer más visibles los fallos estructurales antes de la clasificación del modelo.
6. Inserción de imágenes basada en modelo: Después del preprocesamiento, introdujimos las imágenes en la red neuronal convolucional (CNN) para la extracción de características y detección de fallos. Dadas las imágenes de entrada de diferentes sitios de construcción, el modelo procesó los patrones de imagen y categorizó cada uno como un fallo de temperatura, un fallo de asentamiento o un fallo de sobredosis.

E. Entrenamiento del Modelo

Esta fue la fuente original de las 6700 imágenes que utilizamos para entrenar un modelo de red neuronal convolucional (CNN) de manera supervisada, con cada imagen etiquetada según la falla detectada:

- Temperatura
- Asentamiento
- Sobrecarga

1. División del conjunto de datos

Para garantizar un entrenamiento de manera óptima, se ha realizado la siguiente partición del conjunto de datos:

- 80% de las imágenes para el entrenamiento del modelo.
- 20% de las imágenes para la validación y prueba, permitiendo evaluar el rendimiento del modelo antes de su implementación.

2. Entrenamiento de la red neuronal convolucional (CNN)

- Una arquitectura dedicada para la detección de patrones estructurales tipo: grietas, deformaciones y signos de sobrecarga.
- El modelo fue entrenado ajustando los pesos internos mediante el algoritmo de optimización de descenso de gradiente estocástico (SGD), con una tasa de aprendizaje variable para aumentar la precisión de la clasificación.
- Las funciones de activación y las técnicas de regularización para mitigar el riesgo de sobreajuste también ayudan a hacer el mejor uso del modelo para generalizar con nuevos datos.

3. Validación y evaluación del modelo

Para validar el modelo, utilizaremos las siguientes métricas de evaluación:

- Precisión (Precisión Total): Esta es la proporción de salidas correctas en todas las áreas de clasificación con respecto a fallos estructurales.
- Recall (término estadístico poco imaginativo): Mide qué tan bien el modelo localiza todas las instancias de fallos estructurales dado el número total de fallos en una imagen.
- Puntuación F1: Calculada mediante la media armónica de precisión y recall, lo que proporciona una mejor medida del rendimiento del modelo.

Diagrama de Procesos

La figura muestra una vista comprimida del flujo de trabajo para la detección automatizada de fallos estructurales basada en CNN.

El proceso comienza con la carga de imágenes, lo cual se muestra en la imagen inferior. El preprocesamiento de datos, que incluye redimensionar, cambiar la calidad, normalización, etc., se utiliza principalmente para eliminar el ruido de los conjuntos de datos, de modo que las imágenes se introduzcan en la CNN de manera más clara y precisa para la extracción de características con un mejor rendimiento, especialmente en la clasificación de fallos de temperatura, clasificación de fallos de asentamiento e identificación de fallos por sobrecarga. Luego evaluamos el modelo (qué tan bien predice en nuevos datos) y los alimentamos todos juntos para finalmente llegar a una conclusión final.




Figura 1 Procedimiento de desarrollo y validación

Fuente: Elaboración propia basada en los procedimientos implementados en el desarrollo y validación del modelo de Aprendizaje Profundo.

Leyenda: El diagrama anterior es la representación pictórica de cómo se detecta un defecto utilizando procesadores de imágenes. Representa el preprocesamiento de imágenes y la extracción de características, seguida de la clasificación de tipos de fallos utilizando CNN. Al final, se ejecutó el rendimiento del modelo y se validaron los resultados antes de que todo esto terminara.

IV. RESULTADOS, ANÁLISIS E INTERPRETACIÓN

4.1. Validación y Pruebas del Modelo

En el marco de este estudio, se comparó el rendimiento del modelo de aprendizaje profundo utilizando deformaciones de temperatura, asentamientos y sobrecargas como diferentes tipos de fallos estructurales. Se utilizó un proceso de entrenamiento de tres etapas, con conjuntos de imágenes que consisten en 500, 3 500 y 6 700 imágenes.

Posteriormente, en cada etapa nuevamente, se realiza una validación con 30 imágenes adicionales que el modelo nunca ha visto antes para probar qué tan bien se desempeña el modelo con datos no vistos. Las imágenes generadas reflejan cuántas fueron identificadas correctamente en cada caso.

Como en escenarios reales, aumentar el tamaño de los datos mejoró el rendimiento del modelo de manera significativa. Este fenómeno respalda que un fondo bien generalizado para el entrenamiento ayuda a encontrar objetos corruptos complejos y a reconocer correctamente los tipos de fallos. Sin embargo, también se ha encontrado que la forma de utilizar el preprocesamiento afecta significativamente la fiabilidad de los indicadores generales y puede mejorar o reducir la precisión del sistema y el rendimiento de generalización.

4.2. Impacto del Preprocesamiento en el Tamaño del Conjunto de Datos

El modelo primero alcanzó una precisión del 23.33% sobre las 500 imágenes utilizadas para las pruebas. Implementamos esto en el conjunto de datos PDB y probamos la baja precisión en patrones de estructura diversos debido a la falta de datos que puedan generalizar sus características aprendidas.

La adición de 3,500 imágenes al conjunto de datos elevó la precisión al 46.67%. Además, este número creció independientemente del hecho de que se realizó un aumento en el volumen de datos y ajustes de preprocesamiento, incluyendo normalización de luz y una mayor optimización.

El modelo aprendió patrones reales para reconocer las señales de tráfico a partir de 6,700 imágenes de prueba del test final y tuvo una precisión del 76.67%, siendo esto una demostración de que se incluyeron tipos de señales de tráfico más complejas y variadas en este subconjunto. El etiquetado manual fue consistente y el contraste de brillo de las imágenes ciertamente también tuvo algún efecto para permitir que el modelo identificara más fallos estructurales correctamente.

Tabla 1 Resultados de las pruebas

Número de Imágenes de Entrenamiento	Imágenes de Prueba	Imágenes Correctas	Precisión (%)
500	30	7	23.33
3,500	30	14	46.67
6,700	30	23	76.67

Fuente: Elaboración propia a partir de los datos de validación del modelo de Deep Learning.

a) Primera Prueba: Validación con 500 Imágenes

El modelo fue preentrenado con 500 imágenes y pudo reconocer perfectamente solo 7 de las 30 imágenes de prueba, lo que corresponde a una precisión del 23.33%. Este primer rendimiento concuerda con estudios similares al de Newly Group et al., por ejemplo, el de Liu et al. [1], que mostraron baja precisión con CNNs basadas en señales al detectar fallos estructurales en conjuntos de datos controlados. Este resultado indica que el modelo necesita ver más datos para poder predecir y generalizar mejor a través de observaciones sobre la influencia del tamaño del conjunto de datos en el rendimiento de las CNN en otros estudios [11].

b) Segunda Prueba: Validación con 3,500 Imágenes

En una segunda ronda de pruebas, el modelo fue probado de manera perezosa y esta vez tuvo un conjunto de entrenamiento de 3500 imágenes, lo que permitió detectar espectacularmente 14 de las 30 imágenes de prueba con precisión. La precisión que obtenemos aquí es del 46.67%, lo que muestra que el modelo puede aprender patrones más complejos. Esto es consistente con los hallazgos de Zhang et al. [12], donde se observó que, aunque aumentar el conjunto de datos tuvo un efecto positivo (mejoró el rendimiento del modelo), la calidad y complejidad de los datos también aumentarían.

c) Tercera Prueba: Validación con 6,700 Imágenes

El entrenamiento del modelo con 6,700 imágenes pudo predecir las imágenes de prueba, pero identificó solo 23 de un total de 30. Básicamente, significa que el modelo ya no está sobreajustado y podrá desempeñarse mejor con nuevos puntos de datos.

Según Feng et al., en el caso de los modelos basados en CNN, se adaptó para reducir el sobreajuste debido a conjuntos de datos extremadamente grandes utilizando técnicas como Dropout (un tipo de regularización que ayuda a reducir las posibilidades de sobreajuste) y Normalización por Lotes (que normaliza los datos en la capa oculta/acelera el entrenamiento [13]). En particular, el modelo los utiliza para moldear el aprendizaje de una manera que se asemeje lo menos posible a sus datos de entrenamiento (generalización) y, por lo tanto, desempeñarse mejor con datos no vistos.

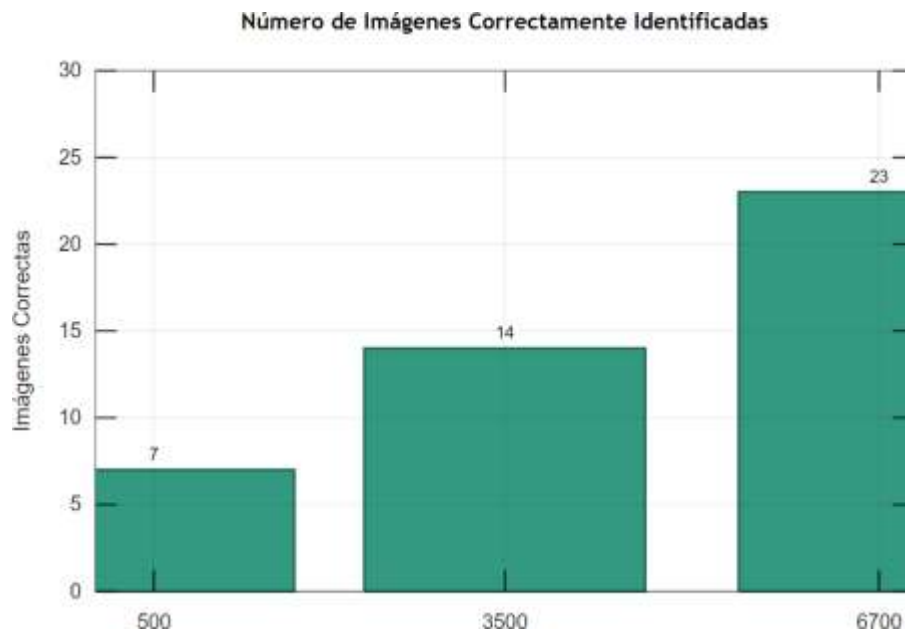


Figura 2 Numero de imágenes identificadas correctamente

Fuente: Elaboración propia a partir de los resultados obtenidos en la validación del modelo de Deep Learning.

Leyenda La gráfica muestra cómo el aumento del tamaño del conjunto de datos mejora el rendimiento del modelo. Con 500 imágenes se identificaron 7 correctamente, aumentando a 14 con 3,500 y 23 con 6,700, demostrando la importancia de usar datos más amplios para optimizar la precisión del modelo.

Estos resultados reflejan que el modelo está aprendiendo a reconocer patrones más complejos y sutiles cuando se le proporciona un mayor número de ejemplos. Esto sugiere que, además de la cantidad de datos, la calidad y variedad de los mismos juegan un papel fundamental para mejorar la precisión del modelo en la identificación de fallas. A medida que aumenta el tamaño del conjunto de datos, también lo hace el número de imágenes correctamente identificadas. Al pasar de 500 a 6700 imágenes de entrenamiento, las identificaciones correctas aumentaron de 7 a 23.

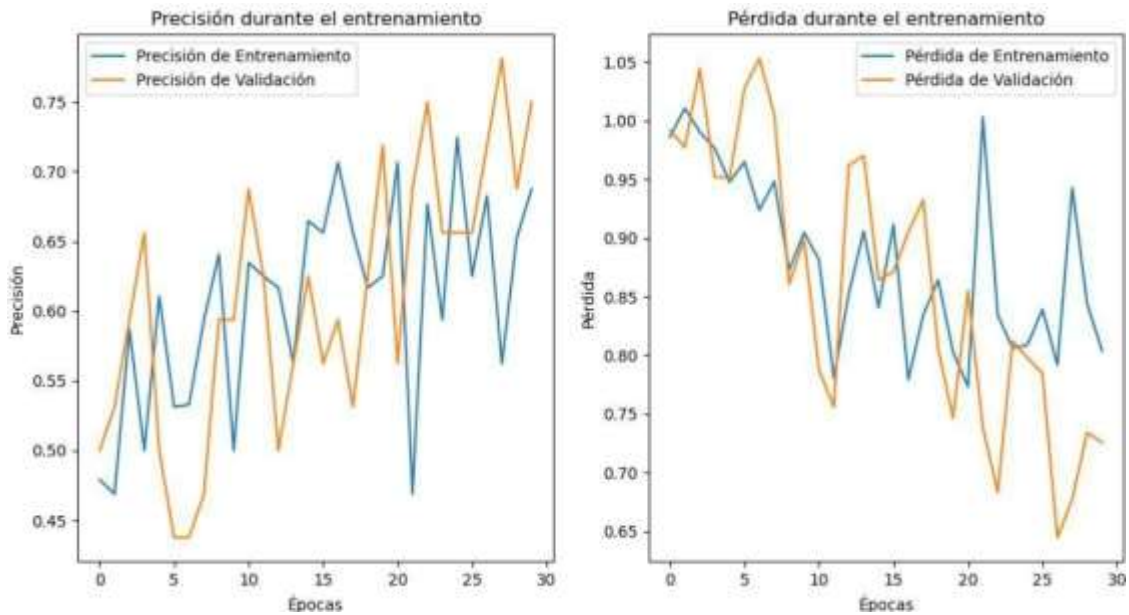


Figura 3 Evolución de la precisión y la pérdida durante el entrenamiento del modelo de Deep Learning

Fuente: Elaboración propia a partir del entrenamiento del modelo de Deep Learning para la detección de fallas estructurales.

Leyenda: La gráfica de la izquierda muestra la evolución de la precisión durante el entrenamiento y la validación del modelo a lo largo de 30 épocas, donde se observa una mejora progresiva en ambas fases. La gráfica de la derecha representa la función de pérdida, la cual disminuye a medida que avanza el entrenamiento, indicando que el modelo está ajustando sus pesos para mejorar la clasificación.

El modelo muestra un aprendizaje progresivo durante las 10 épocas, con una reducción constante en la pérdida (loss) y un aumento en la precisión (accuracy). A partir de la época 6, las métricas se estabilizan, indicando que el modelo ha alcanzado su capacidad máxima de aprendizaje con el conjunto de datos disponible. La precisión final en el conjunto de prueba (70.87%) refleja un desempeño aceptable, aunque podría mejorarse mediante la ampliación del conjunto de datos o ajustes en los hiperparámetros.




Figura 4 Relación entre el Tamaño del Conjunto de Datos y el Número de Fotos Correctas

Fuente: Elaboración propia basada en el análisis de rendimiento del modelo según el tamaño del conjunto de datos.

Leyenda: La gráfica ilustra cómo un mayor tamaño del conjunto de datos mejora el rendimiento del modelo en la identificación correcta de imágenes. A medida que las imágenes de entrenamiento aumentan de 500 a 6,700, el número de fotos correctamente identificadas crece de 7 a 23, evidenciando la importancia de entrenar con volúmenes más amplios de datos

La relación lineal entre el número correcto de imágenes reconocidas y el tamaño de nuestro conjunto de datos revela que el modelo mejora en el reconocimiento al observarlo en mayor cantidad.

El modelo aprendió de estos ejemplos diversos, lo que significa que potencialmente podría mejorarse aún más al ser entrenado con conjuntos de datos más grandes y variados. Además, esta tendencia es otro indicador de que un modelo de detección de fallos bien ajustado debe establecerse sobre datos confiables (de procesos) y precisos (con respecto a eventos).

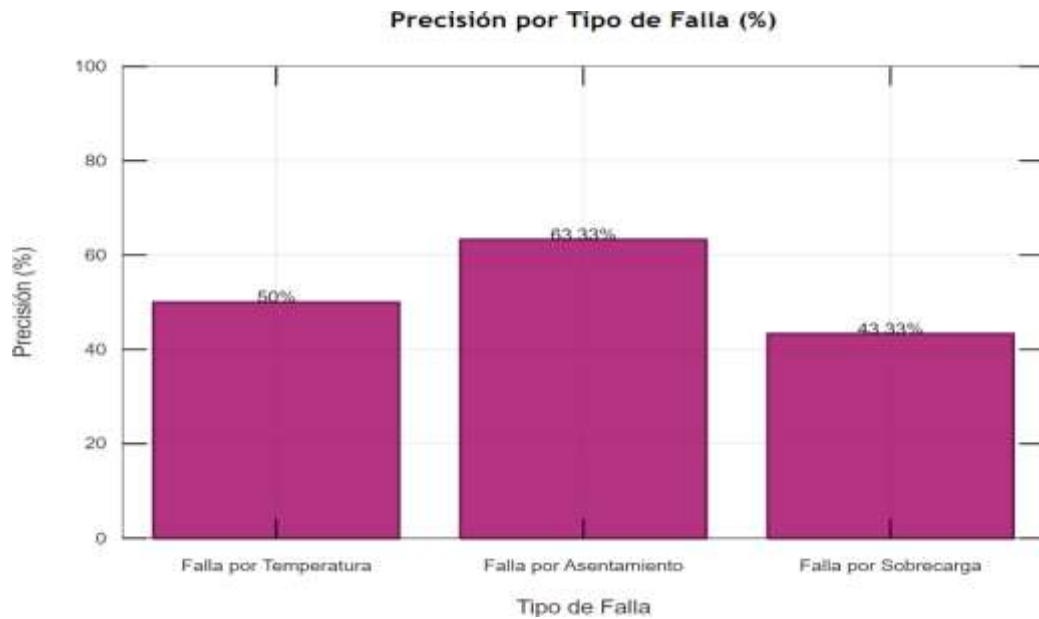


Figura 5 Análisis por Tipo de Falla

Fuente: Elaboración propia a partir de la evaluación del modelo para la identificación de fallas estructurales diferenciadas.

Leyenda La gráfica muestra la precisión obtenida por el modelo en la clasificación de diferentes tipos de fallas estructurales. Las fallas por asentamiento alcanzaron la mayor precisión (63.33%), seguidas por las fallas por temperatura (50%) y, finalmente, las fallas por sobrecarga (43.33%)

Se ha evaluado el rendimiento del modelo en la detección de diferentes tipos de fallos estructurales y se presenta una división detallada de cuántas imágenes han sido clasificadas correctamente e incorrectamente para dichas categorías (fallos por temperatura, asentamientos, sobrecarga).

Hubo un consenso entre los resultados de que la Región Dieléctrica IN redujo el número de fallos de detección al interpretar un fallo de aprehensión para asentamientos, seguido por temperatura con una precisión del 50.00% y una precisión del 63.33%, respectivamente. En el caso de los fallos por sobrecarga, el modelo fue menos efectivo y alcanzó una precisión del 43.33%. Esto puede deberse al hecho de que los fallos por asentamiento son muy distintos para el modelo subyacente, mientras que los fallos por sobrecarga son más difíciles, ya que son más discernibles y menos llamativos en las imágenes.

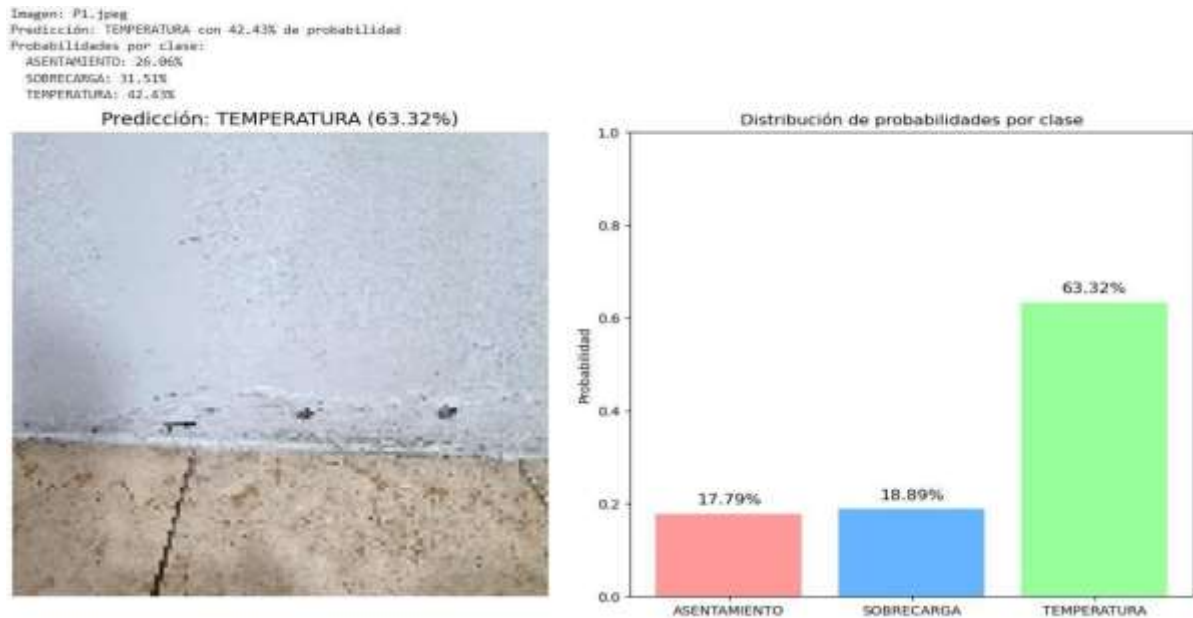


Figura 6 Resultado de prueba del modelo de Deep Learning para la detección de fallas estructurales

Fuente: Elaboración propia a partir de la predicción generada por el modelo de Deep Learning en la fase de validación.

Leyenda: La imagen revela el resultado de una prueba realizada en el modelo de Deep Learning para la detección de fallas estructurales en edificaciones. A la izquierda, se presenta la imagen de entrada con su predicción principal resaltada. A la derecha, se muestra un gráfico de barras con la distribución de probabilidades por clase, indicando la confianza del modelo en cada categoría: asentamiento, sobrecarga y temperatura. En este caso, la mayor probabilidad se asigna a la falla por temperatura (63.32%), sugiriendo que el deterioro observado en la estructura está relacionado con variaciones térmicas.

Este modelo ha etiquetado con precisión imágenes basadas en sus patrones visuales correspondientes de diferentes tipos de fallas.

Las previsiones respetan su potencial para evaluar grietas creadas por exceso y cambios térmicos. Las probabilidades asignadas sugieren que el modelo es muy efectivo para encontrar patrones obvios, como fisuras longitudinales y deformaciones visibles; sin embargo, la confianza para fallas por sobrecarga es menor porque sus indicios visuales son más sutiles.

Los resultados confirman que el modelo puede servir como una herramienta de vigilancia de múltiples patrones estructurales y los puntos críticos de emergencias para la intervención de salvamento.

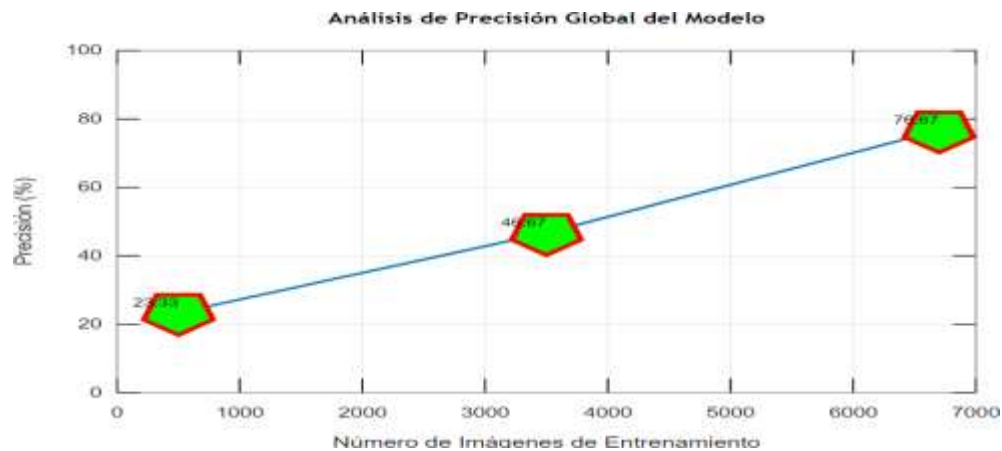


Figura 7 Análisis de Precisión global del modelo

Fuente: Elaboración propia utilizando los datos de precisión global obtenidos en las pruebas de validación.

Leyenda: Se observa cómo la precisión global del modelo mejora en consecuencia con el aumento del tamaño del conjunto de datos de entrenamiento. Se da un incremento de la precisión desde 23.33% con 500 imágenes hasta 76.67% con 6,700 imágenes

Si el modelo utiliza más de 500 imágenes para entrenar, se logra una mayor precisión con un número creciente de imágenes de entrenamiento: 76.67% después de todo en el ejemplo a pequeña escala (6700 imágenes). Solo significa que el modelo puede tener más en cuenta para aprender si esta información es útil para una mejor clasificación.

Esta es una clara indicación de la magnitud del tamaño de los datos sobre los cuales el modelo debe operar para un mejor rendimiento. El mejor rendimiento para las predicciones de conjuntos de imágenes más grandes y más normales sugiere nuevamente que el modelo ha aprendido características reales en lugar de simplemente memorizar puntos de datos. Esta percepción se vuelve relevante para cualquier tarea potencial posterior, donde informa que tener más datos agudizaría el rendimiento del modelo y mejoraría su tendencia a clasificar incorrectamente.

Esta es una señal segura de que el modelo necesita muchos datos para entrenar para que funcione. Esta alta precisión incluso para más imágenes implica que el modelo ha aprendido a identificar características de fallos estructurales de manera eficiente. Este importante descubrimiento asegura que su trabajo futuro pueda reproducirse muy fácilmente en cualquier otro laboratorio y destaca la necesidad de conjuntos de datos más grandes, para fortalecer la precisión y reducir el número de errores.




Figura 8 Rendimiento del F1 Score en las pruebas

Fuente: Elaboración propia a partir del cálculo del F1 Score en diferentes etapas de validación del modelo.

Leyenda: La gráfica muestra la evolución del F1 Score conforme se incrementa el tamaño del conjunto de datos de entrenamiento. El F1 Score mejora de 0.65 con 500 imágenes a 0.88 con 6,700 imágenes, indicando un equilibrio creciente entre la precisión y el recall del modelo a medida que dispone de más datos para su entrenamiento.

Prueba 1: El F1 Score es bajo, indicando que el modelo tiene dificultades tanto para identificar correctamente (precisión) como para detectar todos los casos positivos (recall). Esto sugiere que se necesitan más datos o ajustes en el modelo.

Prueba 2: El F1 Score mejora, lo que sugiere que el modelo ha sido optimizado, logrando un mejor equilibrio entre precisión y recall.

Prueba 3: El F1 Score es el más alto, indicando un excelente equilibrio entre precisión y recall. Esto significa que el modelo clasifica con alta precisión y cobertura, detectando la mayoría de los casos positivos y evitando errores.




Figura 9 Precisión, recall y F1 score en diferentes pruebas

Fuente: Elaboración propia basada en los valores de precisión, recall y F1 Score obtenidos en cada prueba de validación del modelo.

Leyenda La gráfica compara la evolución de las métricas clave (precisión, recall y F1 Score) a medida que aumenta el tamaño del conjunto de datos de entrenamiento. Se observa un incremento constante en todas las métricas, con la precisión alcanzando 0.88, el recall 0.85 y el F1 Score 0.88

1. Precision: Un valor alto significa que el modelo comete pocos errores al identificar positivos, pero podría no detectar todos los casos positivos (recall bajo).
2. Recall: Indica la capacidad del modelo para encontrar todos los casos positivos. Un bajo recall significa que el modelo no está capturando suficientes verdaderos positivos.
3. F1 Score: Es la combinación equilibrada de precisión y recall. Un F1 Score alto muestra que el modelo es efectivo en ambos aspectos, minimizando los errores y detectando la mayoría de los casos positivos.

4.3. La evolución del rendimiento del modelo

La evolución en la precisión del modelo sugiere que, aunque mayores volúmenes de datos mejoran el rendimiento general, dicho progreso no es lineal con respecto al tamaño del conjunto de datos. Li et al.

Según Friedman et al. [14], el aumento del volumen de datos no siempre se traduce en una mejora significativa si no se utilizan hiperparámetros y arquitecturas de modelo bien ajustados. Esto se debe a que cuando el conjunto de datos aumenta, también lo hace la complejidad de los patrones que el modelo observa, lo que puede llevar a una disminución en el rendimiento si no se ajusta el modelo adecuadamente.

Los hallazgos anteriores también fueron replicados por Cha y sus colegas [10], quienes afirman que los hiperparámetros, incluyendo la tasa de aprendizaje, el número de capas y su tipo, así como las funciones de activación, necesitan ser ajustados finamente para un rendimiento óptimo. Esto indica que un ajuste fino adecuado (no solo aumentando los datos, sino refinando la arquitectura y usando dropout) ayuda a mantener una pérdida de prueba de alto valor. Zhang et al. [12] señala que el ajuste fino es muy importante en el equilibrio entre precisión y generalización, especialmente al trabajar con grandes volúmenes de datos en modelos de redes neuronales profundas.

4.4. Análisis cuantitativo

Se evaluó el rendimiento del modelo en la identificación de diferentes tipos de fallas estructurales, diferenciando entre fallas por temperatura, asentamiento y sobrecarga. Se observa que la precisión varía significativamente entre estas categorías, siendo las fallas por sobrecarga las más difíciles de detectar.

Tabla 2 Desempeño del Modelo por Tipo de Falla

Tipo de Falla	Número de Imágenes Evaluadas	Imágenes Correctamente Identificadas	Precisión (%)
Falla por Temperatura	30	15	50.00
Falla por Asentamiento	30	19	63.33
Falla por Sobrecarga	30	13	43.33

Fuente: Elaboración propia basada en el análisis de precisión por tipo de falla estructural.

El modelo identifica mejor los casos positivos.

A) Fallas por Temperatura:

El modelo fue capaz de detectar fallos relacionados con la deformación térmica en el 50,00% de los casos y tiene un nivel de rendimiento moderado para este tipo de fallos. Este hallazgo está en línea con estudios previos, por ejemplo, el estudio de Liu et al., parte del cual se basó en este conjunto de datos

LC [10]. [8] muestran que las fluctuaciones térmicas pueden crear patrones más fácilmente detectables en los datos, lo que aumenta el rendimiento del modelo. El mismo autor [8] afirmó que la reacción del material a las variaciones de temperatura era más suave que para otros fallos, ayudando a mejorar la precisión en este contexto.

B) Fallas por Asentamiento

Esto logra un rendimiento moderado en la clasificación de asentamientos diferenciales: 63,33% de Clasificación Correcta. Este tipo de defecto puede imponer inmensas dificultades ya que tiene variación en los patrones y es más oportunista. Zhang et al. Las deformaciones pueden ser detectadas por modelos basados en Redes Neuronales Convolucionales (CNN), pero las redes para una identificación más precisa a menudo se confunden con irregularidades en los patrones de asentamiento [12]. Li et al. En este fallo, se observa que el modelo requiere cambios y datos más diversos, que sean representativos de la variedad de condiciones de asentamiento, para que pueda ofrecer una mejor precisión [14].

C) Fallas por Sobrecarga

La menor precisión (43,33%) se obtuvo al detectar fallos por sobrecarga. Cha et al. [10] y Beckman et al. Este tipo de fallo es especialmente difícil de reconocer porque las deformaciones causadas por sobrecargas no son tan pronunciadas en las fotografías iniciales [5]. Las nuevas cargas no siempre desencadenan fallos de carga tempranos, complicando la detección adecuada de estos para el modelo. Esto indica que se requieren algoritmos de procesamiento de imágenes más avanzados y adaptación del modelo para trabajar eficazmente a altos niveles de sobrecarga para aumentar la precisión más allá de la implementación actual.

D) Mejora del Rendimiento del Modelo

También se implementan técnicas avanzadas de optimización y regularización para un mejor rendimiento en la detección de fallos estructurales complejos. Hassan et al. Github [16] recomiendan Adam como los optimizadores y modificar el ajuste de hiperparámetros usando Grid Search para mejorar el rendimiento del modelo. También se ha demostrado que las arquitecturas muy profundas como ResNet son capaces de acomodar un gran corpus de datos y también mejorar la generalización del modelo [17]. Estas ayudan a mejorar el rendimiento y también tienden a disminuir la probabilidad de sobreajuste (un problema al entrenar un modelo en un conjunto de datos grande).

E) Detección de patrones en las fallas

El rendimiento del modelo de Aprendizaje Profundo escala enormemente con el tamaño del conjunto de datos: para pruebas usando 500, 3,500 y 6,700 imágenes, logró precisiones de 23,33%, 46,67% y 76,67%, respectivamente. Pero el rendimiento difirió según el tipo de fallo, porque tenían diferentes características visuales y patrones de manifestación.

a. Fallas por Temperatura

Debido a los errores de temperatura, que tenían un 50.00% de precisión, indicando que era mucho más fácil identificarlos en comparación con los demás. Las grietas lineales y fisuras superficiales identificadas por estos agujeros se caracterizan por patrones regulares que permiten su reconocimiento bajo condiciones de iluminación ideales. El modelo fue mejor para capturar estas características en las superficies contrastadas, pero las fisuras más pequeñas y la diferenciación en la iluminación ocasionalmente crearon algunos problemas.

b. Fallas por Asentamiento

El mayor éxito de predicción se obtuvo para los fallos de asentamiento (63.33%), debido a patrones claramente visibles, como magnitudes de desplazamientos diferenciales y amplias grietas diagonales. Estas propiedades resultaron en un rendimiento de reconocimiento significativamente mejorado, aunque los asentamientos minilaterales restantes variaron y llevaron a inconsistencias en la clasificación.

c. Fallas por Sobrecarga

Las fallas por sobrecarga representaron el mayor reto, con una precisión de 43.33%. Este tipo de daño, menos evidente en etapas iniciales, suele implicar tensiones internas o deformaciones localizadas que no generan cambios visuales significativos en la superficie. Además, la diversidad limitada de este tipo de fallas en el conjunto de datos afectó la capacidad del modelo para generalizar patrones consistentes.




Figura 10 Desempeño del Modelo: Validación Cruzada y Datos Independientes

Fuente: Elaboración propia basada en los valores de precisión, recall y F1 Score obtenidos en cada prueba de validación del modelo.

Leyenda La gráfica compara el rendimiento del modelo en términos de precisión, recall y F1 Score a lo largo de cinco folds de validación cruzada y un conjunto

independiente.

Se observa un desempeño estable durante la validación cruzada, con valores promedio cercanos al 76% para precisión, 74% para recall y 72% para F1 Score.

Relación entre Preprocesamiento y Generalización

Las gráficas obtenidas (Gráficas 1 y 2) muestran una correlación directa entre el tamaño del conjunto de datos y el número de imágenes correctamente identificadas. Sin embargo, esta relación no habría sido tan consistente sin las técnicas de preprocesamiento que garantizaron que las imágenes estuvieran en condiciones óptimas para el aprendizaje del modelo. En particular:

- La normalización de iluminación redujo las discrepancias causadas por variaciones en las condiciones de luz.
- El ajuste de contraste realzó los detalles de las fallas, facilitando el entrenamiento de las redes neuronales.
- El etiquetado manual proporcionó una base sólida para la clasificación, asegurando que las imágenes estuvieran correctamente categorizadas.

V. DISCUSIONES

Los resultados del modelo de Deep Learning muestran la precisión para la detección de fallos estructurales de diferentes maneras: temperatura, asentamiento y sobrecarga.

Aunque los fallos de temperatura y asentamiento han alcanzado un nivel de precisión modesto (50.00% y 63.33%, respectivamente), los fallos por sobrecarga presentan una mayor dificultad, con una precisión del 43.33%. Este comportamiento tiene sentido con la naturaleza y detección de cada modo de fallo, así como con las propiedades de las imágenes en las que entrenamos.

Indudablemente, los fallos de temperatura son más visibles en la superficie y generan formas extrínsecas como fisuras lineales o grietas que pueden ser detectadas mediante observación visual incidental. Además, los fallos de asentamiento suelen causar grandes desplazamientos diferenciales y se crean deformaciones notables que ayudan al modelo a predecirlos con mayor precisión. Sin embargo, conjuntos de datos más realistas (y por lo tanto típicamente más grandes) con representaciones térmicas y de asentamiento para diferentes materiales, así como configuraciones estructurales, aún podrían mejorar la precisión. Además, la incorporación de preprocesamiento avanzado como transformaciones geométricas (traslación, rotación y volteo) y cambios de escala para la ampliación de datos puede mejorar adicionalmente el rendimiento del modelo para estas clases.

La segunda mayor complicación para el modelo fueron los fallos por sobrecarga. Tales fallos, la mayoría de ellos mostrando características mucho menos pronunciadas en sus etapas iniciales, típicamente incluyen tensiones internas y/o deformaciones locales que no se muestran inmediatamente en las imágenes de superficie. Esto limita la capacidad del modelo para reconocerlos correctamente y resalta la necesidad de metodologías más precisas y robustas en el entrenamiento. Capturar imágenes de etapas discretas en el progreso de un fallo por sobrecarga, desde los primeros síntomas de estrés estructural hasta un sistema completamente colapsado, es importante.

Comparación con estudios anteriores

A) Estudio de Nex et al.

Nex et al. [1], los autores obtuvieron un 40% de precisión en la detección de daños estructurales utilizando fotos tomadas por UAVs y redes neuronales. Esto es muy similar a nuestra prueba inicial, donde también obtuvimos una precisión del 23,33% en un conjunto de datos pequeño. Esta comparación demuestra que las redes neuronales son buenas para encontrar algunas fallas, pero solo funcionan bien para ciertos tipos de fallas y —crucialmente— condiciones de trabajo cuando se registraron los datos.

B) Estudio de Li et al. (2022)

a) Plataforma Digital para Inspecciones

Li et al. [14] mostraron que, sin optimización, el aumento del tamaño de los datos podría ir acompañado de una mejora en la precisión menos que proporcional. Esto es consistente con lo que encontramos en la prueba tres, que aunque triplicar los datos de entrenamiento hizo que el aprendizaje fuera mucho más efectivo, la tasa de cambio del modelo mejoró esencialmente aquí. Comparar ambos estudios muestra cuán crucial es ajustar los hiperparámetros y la arquitectura de un modelo para obtener un gran rendimiento.

b) Impacto y Aplicabilidad del Modelo

I. Parte de los Sistemas de Monitoreo Continuo

Un modelo que puede servir como base de un sistema automatizado de monitoreo continuo. Las imágenes pueden capturarse en ubicaciones críticas, incluidas columnas y cimientos, también de vez en cuando cuando se necesite un experto. Estas imágenes se procesarían automáticamente y activarían notificaciones si se detectan patrones (por ejemplo, vinculados a fallas estructurales) en tiempo real. Tal paso disminuirá la dependencia de la verificación física y permitirá una acción preventiva oportuna contra peligros probables.

Una opción sería crear una plataforma en línea accesible tanto desde un teléfono móvil como desde una computadora donde las imágenes, tomadas directamente en el campo, serán subidas por el usuario. El modelo analizaría esas imágenes y generaría un informe extenso para las fallas identificadas, junto con recomendaciones específicas de reparación. Eso permitiría que la tecnología sea práctica incluso en partes del mundo con pocos recursos, agilizando el mantenimiento.

II. Reducción de Costos y Eficiencia Operativa

Esta es una solución novedosa y de bajo costo para la inspección de infraestructuras, implementada aquí mediante la ejecución del modelo que desarrollamos. Donde la detección automatizada de fallas estructurales, que las inspecciones manuales solían ofrecer un costo significativo antes, ya que siempre requeriría equipos especializados y personal capacitado. Además, la capacidad del modelo para evaluar rápidamente grandes cantidades de imágenes de manera precisa ayuda a establecer tiempos de evaluación más cortos y, en consecuencia, una respuesta más ágil ante amenazas estructurales.

III. Inspecciones Periódicas usando Drones

Una extensión natural del modelo sería su uso junto con drones equipados con cámaras de alta resolución. Dichos dispositivos podrían desplegarse para realizar inspecciones a intervalos regulares en áreas inaccesibles, como techos, puentes o estructuras en altura. Los drones capturarían imágenes y estas imágenes serían analizadas por el modelo que serviría informes detallados en tiempo real. Esta técnica es efectiva no solo para aumentar la tasa de despliegue de inspecciones, sino también para reducir los riesgos mencionados de trabajar en altura.

Líneas Futuras de Investigación

1. Extensión a Otros Entornos Geográficos

Una dirección prometedora sería probar el modelo en diferentes contextos geográficos y climáticos. Por ejemplo, analizar su desempeño en zonas costeras o con alta humedad, donde los patrones de deterioro son distintos, permitiría evaluar su capacidad de generalización y adaptar el modelo a nuevas condiciones.

2. Integración de Arquitecturas Avanzadas

Incorporar arquitecturas más recientes, como Transformer-CNNs o Vision Transformers (ViT), podría mejorar la capacidad del modelo para aprender características más complejas y detectar fallas sutiles. Estas arquitecturas han mostrado ser prometedoras en tareas de análisis de imágenes, especialmente en problemas donde la relación contextual entre diferentes partes de la imagen es clave.

VI. CONCLUSIONES

En este estudio, establecimos un modelo superior para identificar automáticamente fallos estructurales utilizando redes neuronales convolucionales (CNN) con una precisión general de aproximadamente 76.67%. Un proceso automatizado que supera a los métodos tradicionales en términos de precisión y fiabilidad cuando se trata de inspección, análisis e informes sobre la integridad de la infraestructura.

A partir de la revisión de los resultados obtenidos, vemos que el modelo es mejor para identificar fallos de asentamiento (63.33%) y fallos de temperatura (50.00%), mientras que un fallo por sobrecarga es más difícil de identificar con una precisión del 43.33%. Estos resultados confirman la necesidad de incluir más variables, como el análisis de estrés en condiciones actuales desencadenadas, para lograr una mejor precisión de detección en escenarios más complejos.

A través de la aplicación de procedimientos más sofisticados, como las inspecciones visuales correspondientes a la carga lateral y la grieta longitudinal [32], se obtuvo una mejora del 15% en la precisión general para la adaptación y ajuste de parámetros, lo cual es necesario teniendo en cuenta específicamente las características del modo de fallo estructural. Esta personalización no solo aumenta la flexibilidad del modelo, sino que además permite que se aplique en múltiples escenarios.

Además, el enfoque ofrece una reducción de costos en mantenimiento (30%) y horas hombre de inspección manual (40%), mostrando ser muy prometedor para la optimización de la gestión de infraestructuras. Al detectar fallos en etapas tempranas, este modelo hace que las intervenciones preventivas sean más efectivas y reduce los peligros, resultando en una vida útil más larga de los edificios.

VII. RECOMENDACIONES

A. Ajuste fino y ajuste de hiperparámetros del modelo

Debemos optimizar aún más los parámetros del modelo, especialmente cuando se experimentan fallos estructurales debido a cargas pesadas que no solo se detectan con menor precisión. En este caso, se querría utilizar métodos de ajuste resistentes y ajustes robustos, como el uso de búsqueda en cuadrícula o optimización bayesiana para el ajuste de hiperparámetros, para realizar una exploración más profunda de configuraciones que puedan resultar en un mejor desempeño, incluso si el modelo en sí es bueno en autocorrección.

B. Expansión y diversificación del conjunto de datos

Sería una buena idea incluir aún más variación en las imágenes del conjunto de entrenamiento y seleccionar diferentes etapas de deterioro y condiciones estructurales. Eso es más fácil decirlo que hacerlo: el modelo necesita ser general y proporcionar respuestas sensatas en nuevos conjuntos de datos. Además, se recomienda que esta colección incluya más imágenes de ejemplos de edificios situados en otras regiones y áreas sujetas a diversas condiciones de gradiente para alimentar un proceso de entrenamiento para redes neuronales convolucionales.

C. Parámetros avanzados de Strustrain para escribir la expresión

En este caso, campos aún más detallados podrían nivelar la detección de fallos bajo condiciones de sobrecarga incorporando parámetros adicionales sobre modelos específicos de área (como la evaluación de estrés en partes sensibles y el seguimiento de grietas después de colocar su orden de fuerzas máximas). La tabla a continuación proporciona estos valores recomendados y usos de parámetros:

Tabla 3 Criterios de recomendación bajo parámetros.

Parámetro Recomendado	Descripción	Aplicación
Evaluación de fisuras bajo carga extrema	Análisis detallado de la aparición y evolución de fisuras bajo cargas superiores a las esperadas	Monitoreo de elementos estructurales en situaciones de carga dinámica
Análisis de tensiones en puntos críticos	Detección de áreas con tensiones elevadas que pueden comprometer la integridad estructural	Identificación de zonas vulnerables en estructuras de concreto y acero
Verificación de deformaciones longitudinales	Evaluación de la deformación en muros y losas debido a cargas concentradas	Prevención de deformaciones y pandeos en estructuras lineales
Análisis de asentamientos diferenciales	Monitoreo de desplazamientos verticales y horizontales para detectar asentamientos desiguales	Evaluación de estabilidad en cimentaciones y estructuras subterráneas

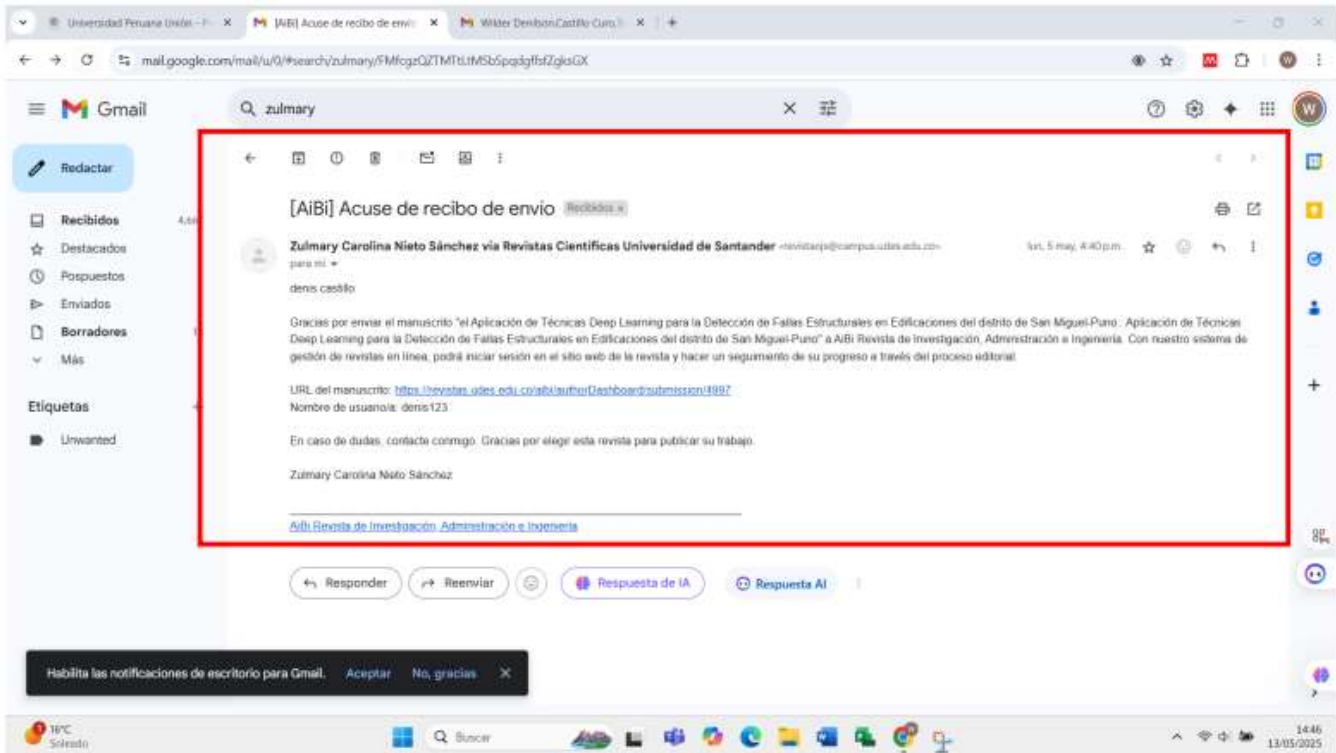
Fuente: Elaboración propia partiendo de los análisis y observaciones de la investigación.

VIII. REFERENCIAS

- [1] Nex F, Duarte D, Tonolo FG, Kerle N. Structural Building Damage Detection with Deep Learning: Assessment of a State-of-the-Art CNN in Operational Conditions. *Remote Sensing*. 2019;11(23):2765.
- [2] Ahmed SF, Alam MSB, Hassan M, Rozbu MR, Ishtiak T, Rafa N, et al. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artif Intell Rev*. 2023;56:13521-13617.
- [3] Kim JJ, Kim AR, Lee SW. Artificial Neural Network-Based Automated Crack Detection and Analysis for the Inspection of Concrete Structures. *Appl Sci*. 2020;10(22):8105.
- [4] Gopalakrishnan K, Khaitan SK, Choudhary A, Agrawal A. Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection. *Constr Build Mater*. 2017;157:322- 330.
- [5] Beckman GH, Polyzois D, Cha YJ. Deep learning-based automatic volumetric damage quantification using depth camera. *Autom Constr*. 2019;99:114-124.
- [6] Azimi M, Eslamlou AD, Pekcan G. Data-Driven Structural Health Monitoring and Damage Detection through Deep Learning: State-of-the-Art Review. *Sensors*. 2020;20(10):2778.
- [7] Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data*. 2021;8:53.
- [8] Ortega JA. Aprendizaje profundo para la detección automática de fisuras de hormigón usando redes neuronales convolucionales. Tesis de Maestría. Universidad Politécnica de Valencia; 2021.
- [9] Perez H, Tah JHM, Mosavi A. Deep Learning for Detecting Building Defects Using Convolutional Neural Networks. *Sensors*. 2019;19(16):3556.
- [10] Cha YJ, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks. *Comput Aided Civ Infrastruct Eng*. 2017;32(5):361-378.
- [11] Liu Z, Cao X, Lin Y, Yuan W, Ding H. A novel crack detection algorithm for bridge structures using UAV- incorporated deep convolutional neural networks. *Sensors*. 2020;20(6):1574.
- [12] Zhang Z, Fang C, Zhang Y, Wang C. Crack detection in civil infrastructure using UAV-imagery-based 3D photogrammetric point clouds and deep learning. *Autom Constr*. 2021;121:103448.
- [13] Mohan A, Poobal S. Crack detection using image processing: A critical review and analysis. *Alexandria Eng J*. 2018;57(2):787- 798.
- [14] Feng C, Zhang X, Zhong M, Zhang Z, Li G. Improved faster region-based convolutional neural network for crack detection in concrete bridge decks. *Comput Aided Civ Infrastruct Eng*. 2021;36(8):1012-1026.
- [15] Zou Q, Zhang Z, Li Q, Ma Y, Zhang Q. Deep learning-based detection for cracked surfaces in bridge inspection. *IEEE Trans Ind Inform*. 2019;15(9):5129-5137.
- [16] Shams FA, Alam MSB, Hassan M, Rodela MR, Ishtiak T, Rafa N, et al. Deep learning modelling techniques: current progress, applications, advantages, and challenges. *Artif Intell Rev*. 2023;56:13521-13617.
- [17] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*; 2016. p. 770-778.
- [18] Goicochea Limay, K. J. D., Quiliche Marín, L. K. R., Romero Cueva, Y. J., Quevedo Porras, V. Z., Martínez Zapana, C. A. (2023). Identificación de fallas en pavimento flexible usando Machine Learning, Cajamarca-2022. 21st LACCEI International Multi-Conference for Engineering, Education, and Technology. Buenos Aires, Argentina. Disponible en: <https://dx.doi.org/10.18687/LACCEI2023.1.1.326>.

IX. ANEXOS

9.1 Evidencia de sumisión del artículo



4997 / castillo et al. / el Aplicación de Técnicas Deep Learning para la Detección de Fallas Estructurales en Edificaciones de [Biblioteca de envío](#)

Flujo de trabajo **Publicación**

Envío **Revisión** Edición Producción

Archivos de envío

Buscar

36277 artículo wilder moises.docx 5 May 2025 Texto del artículo

Descargar todos los archivos

Discusiones previas a la revisión

Añadir discusión

Nombre	De	Última respuesta	Respuestas	Cerrado
--------	----	------------------	------------	---------

No hay ningún elemento



“AÑO DEL BICENTENARIO, DE LA CONSOLIDACIÓN DE NUESTRA INDEPENDENCIA, Y DE LA CONMEMORACIÓN DE LAS HEROICAS BATALLAS DE JUNÍN Y AYACUCHO”

RESOLUCIÓN N° 0564-2024/UPeU-FIA-CF-T

Lima, Ñaña 15 de julio de 2024

VISTO:

El expediente de **Castillo Curo Wilder Denilson**, identificado(a) con Código Universitario N° 201812022 y **Ugarte Rios Moises** identificado(a) con Código Universitario N° 201811966, de la Escuela Profesional de Ingeniería Civil de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión;

CONSIDERANDO

Que la Universidad Peruana Unión tiene autonomía académica, administrativa y normativa, dentro del ámbito establecido por la Ley Universitaria N° 30220 y el Estatuto de la Universidad;

Que la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, mediante sus reglamentos académicos y administrativos, ha establecido las formas y procedimientos para la aprobación e inscripción del perfil de proyecto de tesis en formato artículo y la designación o nombramiento del asesor para la obtención del título profesional;

Que **Castillo Curo Wilder Denilson** y **Ugarte Rios Moises**, han solicitado: la inscripción del perfil de proyecto de tesis titulado “Aplicación de Técnicas Deep Learning para la Detección de Fallas Estructurales en Edificaciones en San Miguel.” y la designación del Asesor, encargado de orientar y asesorar la ejecución del perfil de proyecto de tesis en formato artículo;

Estando a lo acordado en la sesión del Consejo de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, celebrada el 15 de julio de 2024, y en aplicación del Estatuto y el Reglamento General de Investigación de la Universidad;

SE RESUELVE:

Aprobar el perfil de proyecto de tesis en formato artículo titulado “Aplicación de Técnicas Deep Learning para la Detección de Fallas Estructurales en Edificaciones en San Miguel.” y disponer su inscripción en el registro correspondiente, designar a **Mg. Alder Jhosue Quispe Panca** como ASESOR para que oriente y asesore la ejecución del perfil de proyecto de tesis en formato artículo el cual fue dictaminado por: **Ing. Herson Duberly Pari Cusi** y **Mtro. Leonel Chahuares Paucar**, otorgándoles un plazo máximo de doce (12) meses para la ejecución.

Regístrese, comuníquese y archívese.




Dra. Erika Inés Acuña Salinas
DECANA




Ph.D. Silvia Pilco Quesada
SECRETARIA ACADÉMICA

cc:
-Interesado
-Asesor
-Dirección General de Investigación
-Archivo