

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE
HUAMANGA**

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**Determinación de fisuras y grietas en estructuras de concreto
mediante el procesamiento de imágenes utilizando un modelo de
redes neuronales artificiales en la provincia de Huamanga, 2024**

Para optar el título profesional de:

INGENIERO CIVIL

PRESENTADO POR:

Bach. Freud Watson ESPILLCO QUINTANILLA

ASESOR:

Msc. Ing. Hemerson LIZARBE ALARCÓN

AYACUCHO - PERÚ

2024

Resumen

Actualmente, diversas razones han provocado que los puentes de concreto armado con más de 25 años de antigüedad presenten fisuras y grietas. Estos factores incluyen la falta de control de calidad, el mantenimiento insuficiente, las cargas móviles, las cargas muertas y la fatiga sísmica. En esta investigación, proponemos una metodología alternativa al mantenimiento manual para prolongar la vida útil de estas estructuras.

En esta investigación utilizamos un modelo predictivo basado en una red neuronal ANN(Artificial Neuron network) mas específicamente una red neuronal Convolutiva CNN para poder determinar y clasificar fisuras y grietas en estructuras de concreto en la provincia de Huamanga, departamento de Ayacucho a partir de fotografías y videos.

Se seleccionaron fotografías de diferentes ángulos, perspectivas de los elementos estructurales, almacenarlos, limpiarlos y seleccionarlos para su posterior entrenamiento en un modelo de de redes neuronales artificiales, para poder realizar el entrenamiento de la red neuronal convolutiva se utilizo el 70% de datos y el restante 30% para comprobación de la red neuronal convolutiva.

La arquitectura de nuestra red tiene una capa de entrada llamada Input data donde ingresamos las fotografías y la capa de convolucion se encarga de aprender patrones de las fotografías procesadas, luego en la capa oculta(Hidden layer) se encarga de determinar por pixeles que significa cada elemento de la fotografía técnicamente hablando convolucion para finalmente entender de que trata la fotografía y sus pixeles, luego esta la capa de salida (Output Data) que nos clasificara que tipo de imagen es de acuerdo a los datos entrenados anteriormente.

concluyendo, mediante la aplicación de redes neuronales convolucionales utilizando fotografías digitales, se logró detectar fisuras y grietas en los elementos estructurales de concreto armado. Esto permitirá su posterior mantenimiento y operación del mismo.

Palabras clave : Grietas, Fisuras, Procesamiento de imágenes, redes Neuronales convolucionales, Concreto armado.

Abstract

Currently, a number of reasons have caused reinforced concrete bridges over 25 years old to crack and crack. These factors include lack of quality control, insufficient maintenance, moving loads, dead loads, and seismic fatigue. In this research, we propose an alternative methodology to manual maintenance to extend the service life of these structures. In this research we use a predictive model based on a neural network ANN (Artificial Neuron network) more specifically a Convolutional Neural Network CNN to determine and classify cracks and fissures in concrete structures in the province of Huamanga, department of Ayacucho from photographs and videos.

Photographs from different angles, perspectives of the structural elements were selected, stored, cleaned and selected for subsequent training in an artificial neural network model. To perform the training of the convolutional neural network, 70% of the data was used and the remaining 30% for the convolutional neural network test.

The architecture of our network has an input layer called Input data where we enter the photographs and the convolution layer is responsible for learning patterns of the processed photographs, then in the hidden layer (Hidden layer) is responsible for determining by pixels that means each element of the photograph technically speaking convoluted to finally understand what is the photograph and its pixels, then there is the output layer (Output Data) that we classify what type of image is according to the data trained above. In conclusion, through the application of convolutional neural networks using digital photographs, it was possible to detect cracks and fissures in reinforced concrete structural elements. This will allow its subsequent maintenance and operation.

keywords : Cracks, Cracking, Image processing, Convolutional Neural Networks, Reinforced concrete.

Introducción

La investigación presentada aborda la determinación e identificación de patologías estructurales en la superficie de concreto utilizando nuevas metodologías y técnicas de evaluación, que son un defecto importante en monitoreo de la salud estructural de las estructuras de concreto armado. El interés de esta investigación se da por buscar nuevas soluciones y rápidas para la evaluación temprana de patologías estructurales, ya que si las fisuras y grietas se desarrollan y continúan propagando y aumentando su tamaño, reducen el área de superficie de carga efectiva y con el tiempo, pueden causar fallas en la estructura de concreto armado. La detección temprana de patologías estructurales permite prevenir posibles daños. Existen varios enfoques para resolver este problema estos son inspección manual y métodos de detección automática. El proceso manual de detección de patologías estructurales consume mucho tiempo y adolece de juicios subjetivos de los inspectores. La inspección manual también puede ser difícil de realizar en el caso de edificios de gran altura y antiguos; sin embargo, hoy en día los métodos de detección automática incluyen no solo pruebas láser y pruebas radiográficas. El progreso de la capacidad de almacenamiento y computación al igual que las redes neuronales artificiales y la visión por computadora nos permite utilizar el procesamiento de imágenes para la detección patologías estructurales en cualquier superficie y a cualquier altura. El avance en la tecnología da nuevos enfoques, como utilizar Redes Neuronales Convolucionales esta ofreciendo nuevas perspectivas y soluciones prácticas para acelerar las innovaciones en el diseño, planificación, operación y mantenimiento en todo el ciclo de vida del proyecto desde esta manera generando un desarrollo en la industria de la construcción. Al aprovechar los conjuntos de datos existentes con modelos basados en datos, utilizando un modelo de redes neuronales artificiales puede aprender automáticamente patrones implícitos y extraer información valiosa y ordenada de los conjuntos de datos. A medida que los modelos de redes neuronales artificiales son cada vez más accesibles para los usuarios, se espera que las aplicaciones se expandan aún más en el sector de la construcción rezagado de las demás industrias que utilizan lo avanzado de la tecnología específicamente denominado industria 4.0.

Humilde homenaje a mi madre fallecida Vinda Claudia Quintanilla Parco, quien en vida ha sido mi mentora, apoyo constante, mi base y una estrella guía en todos y cada uno de los pasos de mi vida. Esto es para ti “Mamá”, tú nos inculcaste el creer en mis sueños y me dio poder para hacerlos realidad.

Gracias a mi familia por ser parte de este sueño cumplido, por creer en mí y en mi proyecto, por estar siempre a mi lado. Sin ustedes, nada de esto hubiera sido posible. Les dedico esta tesis con todo mi cariño y gratitud.

Agradecimientos

Quiero expresar mi sincera gratitud a todas las personas e instituciones que han sido parte fundamental de este viaje académico y de investigación. Sus contribuciones y apoyo han sido invaluableles.

Agradezco al Msc. Ing. Hemerson Lizarbe Alarcón por su guía, paciencia y conocimientos compartidos. Su orientación ha sido esencial para dar forma a este proyecto.

A todos aquellos que me han acompañado en este proceso, gracias por su apoyo, motivación y compañerismo.

A mi familia, por su amor incondicional y constante apoyo. Sin ustedes, este logro no habría sido posible.

A la UNSCH por acogerme en sus aulas y ambientes propicio para poder alcanzar una meta ser un ingeniero civil.

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA

AYACUCHO, SETIEMBRE DE 2024

BACH. FREUD WATSON ESPILLCO QUINTANILLA

Índice General

Resumen	ii
Introducción	v
Dedicatoria	vi
Agradecimientos	vii
Índice General	viii
Índice de Figuras	xii
Índice de Tablas	xiv
Glosarios	xv
Lista de Acrónimos	xvii
Símbolos	xviii

Capítulo I

Planteamiento del Problema	1
1.1. Descripción del problema(mundial, país, región)	1
1.2. Delimitación del problema.....	2
1.2.1. Espacial	2
1.2.2. Temporal	3
1.2.3. Temática y unidad de análisis	3
1.3. Formulación del problema.....	3
1.3.1. Problema general.....	3
1.3.2. Problemas específicos.....	3
1.4. Justificación e importancia.....	4
1.5. Limitaciones de la investigación.....	4
1.6. Objetivo general.....	5
1.6.1. Objetivos específicos.....	5

Capítulo II

Marco Teórico.....	6
2.1. Antecedentes.....	6
2.1.1. Investigaciones internacionales	6
2.1.2. Investigaciones nacionales.....	10

2.2. Bases teóricas	10
2.2.1. Patología estructural.....	10
2.2.2. Procesamiento de Imágenes.....	10
2.2.3. Redes Neuronales Artificiales	11
2.3. Marco conceptual.....	12
2.3.1. Fisuras y grietas	12
2.3.1.1. Clasificación de las fisuras en concreto atendiendo a su tamaño ...	12
2.3.1.2. Clasificación de las fisuras en concreto según su origen o causa ...	13
2.3.2. Modelo de Redes Neuronales Artificiales	15
2.3.2.1. La neurona biológica	15
2.3.2.2. La Neurona Artificial.....	16
2.3.2.3. Elementos básicos de una red neuronal	17
2.3.2.4. Mecanismos de aprendizaje	22
2.3.2.5. Tipos de redes neuronales artificiales	24
2.3.3. Modelo de Redes Neuronales convolucionales	30
2.3.3.1. Imagen de Entrada	30
2.3.3.2. Convolucion.....	31
2.3.3.3. Filtros convolucionales	32
2.3.3.4. Detectores de características	33
2.3.3.5. Equivarianza de traslación.....	34
2.3.3.6. Convoluciones multidimensionales	36
2.3.3.7. Pooling.....	37
2.3.3.8. Clasificación	39
2.3.3.9. Ejemplos de arquitecturas de red	39

Capítulo III

Método de la Investigación	46
3.1. Enfoque	46
3.2. Alcance	46
3.3. Diseño de investigación.....	46
3.4. Población y muestra	47
3.4.1. Población	47
3.4.2. Muestra	47

3.5. Hipótesis	48
3.5.1. Hipótesis general	48
3.5.2. Hipótesis específicas	48
3.6. Operacionalización de variables	48
3.6.1. Variables e indicadores	48
3.7. Técnicas e instrumentos	49
3.7.1. Técnicas	49
3.7.2. Instrumentos	49
3.8. Técnicas estadísticas para el procesamiento de la información	49
3.8.1. Contrastación de Hipótesis por prueba de bondad	50
3.8.2. Prueba de p de chi-cuadrado	51
3.9. Desarrollo del trabajo de tesis	51
3.9.1. Recopilación de Datos	52
3.9.2. Preparación de los Datos	54
3.9.3. Diseño del Modelo de CNN	57
3.9.4. Entrenamiento del Modelo	59
3.9.5. Evaluación del Modelo	62
Capítulo IV	
Resultados.....	63
4.1. Constrastación de la hipótesis	63
4.2. Análisis de resultados	66
Conclusiones	69
Conclusiones	69
Recomendaciones	70
Trabajos futuros	71
Referencias bibliográficas	72
Anexo A	
Script del modelo	75
Anexo B	
Algoritmo y Pseudocódigo	77
Anexo C	
Panel fotográfico	80

Anexo D

Fichas de evaluación de fisuras y grietas en elementos de concreto	86
--	----

Anexo E

Guía de uso del Script	97
E.1. Importación de librerías.	97
E.2. Cargar el Dataset	97
E.3. Etiquetar los Dataset	98
E.4. Creando carpeta de salida	98

Anexo F

Arquitectura de la red neuronal Convolutonal.	99
---	----

Anexo G

Matriz de operacionalidad	101
-------------------------------------	-----

Índice de Figuras

Figura 1	Relación entre la Inteligencia Artificial, Machine Learning Deep Learning y las Redes Neuronales Artificiales.	11
Figura 2	Clasificación de las fisuras en concreto según su origen o causa.	14
Figura 3	Neurona Biológica..	16
Figura 4	Modelo de una red neuronal artificial.	17
Figura 5	funciones de activación.	20
Figura 6	Modelo de una red neuronal artificial multicapa.	21
Figura 7	Relación de aprendizaje supervisado, no supervisado y aprendizaje por refuerzo.	23
Figura 8	Red neuronal Monocapa – Perceptrón simple..	25
Figura 9	Perceptrón multicapa..	25
Figura 10	Red neuronal Convolutiva.	26
Figura 11	Red neuronal Recurrente..	26
Figura 12	Modelo de una red neuronal de memoria a largo plazo LSTM..	27
Figura 13	Modelo de una Red Generativa Adversaria.	28
Figura 14	Red de base radial.	29
Figura 15	Modelo de una Red Neuronal Transformers.	30
Figura 16	Convolucion de una imagen.	31
Figura 17	Muestra una capa oculta de una red que recibe los píxeles de una zona de 3×3.	34
Figura 18	Imagen 3×3 convolucionada con un filtro 2×2 para obtener un mapa de características 2×2.	35
Figura 19	Resultados de la convolución con 2 diferentes filtros que detectan los bordes.	36
Figura 20	Filtro multidimensional que toma datos de los canales R,G y B.	37
Figura 21	Max-pooling de 2×2 píxeles de un mapa de características.	38
Figura 22	Ejemplos de diferentes arquitecturas de redes convolucionales.	40
Figura 23	La arquitectura de una red convolutiva típica llamada VGG-19..	41
Figura 24	Arquitectura de VGG19 y filtros de la primera capa convolutiva	42
Figura 25	Arquitectura de VGG19 y filtros de la segunda capa convolutiva.	43
Figura 26	Arquitectura de VGG19 y filtros de la cuarta capa convolutiva	43
Figura 27	Convolucion multidimensional en los 3 canales RGB	44
Figura 28	Entrenamiento una red neuronal convolutiva en un dataset de dígitos	45

Figura 29	Fotogrametría del puente Huatatas y Chacco.	52
Figura 30	Imágenes con fisuras.	53
Figura 31	Imágenes sin fisuras.	54
Figura 32	Recopilación de las fotografías para el entrenamiento de la red neuronal.	55
Figura 33	Ploteando las imágenes sin fisuras.	56
Figura 34	Ploteando las imágenes con fisuras.	57
Figura 35	Se define un directorio para las imágenes.	58
Figura 36	Construyendo el Modelo de la Red Neuronal Convolucional.	60
Figura 37	Entrenamiento del Modelo de la Red Neuronal Convolucional.	61
Figura 38	Arquitectura de la red neuronal convolucional.	64
Figura 39	Gráfico de entrenamiento y validación a lo largo del tiempo.	66
Figura 40	Matriz de confusión y precisión del modelo.	67
Figura C.1	Vista Panorámica.	80
Figura C.2	Pilar Derecho.	80
Figura C.3	Losa y Vereda.	81
Figura C.4	Pilar Izquierdo.	81
Figura C.5	Vigas y Diafragma.	82
Figura C.6	Vista Panorámica.	82
Figura C.7	Estribo Izquierdo.	83
Figura C.8	Estribo Izquierdo.	83
Figura C.9	Estribo Izquierdo.	84
Figura C.10	Pilar Central.	85
Figura E.1	Librerías como numpy y pandas.	97
Figura E.1	Creando directorios.	97
Figura E.1	Etiquetando imagen del directorio.	98
Figura E.1	Creando las carpetas de salida.	98
Figura F.1	Arquitectura de la red neuronal convolucional.	100

Índice de Tablas

Tabla 1	<i>Ancho máximo en estructuras sometidas a flexión.</i>	13
Tabla 2	<i>Variable e Indicadores.</i>	48

Glosarios

Arquitectura de una red neuronal Es la estructura de capas de neuronas interconectadas, variando en complejidad según el problema, desde una capa de entrada hasta arquitecturas complejas con múltiples capas ocultas.

Datasets Es un conjunto, colección de datos habitualmente tabulada, a los conjuntos de datos muy grandes se les denomina big data.

Descenso por gradiente El descenso de gradiente es un algoritmo que estima numéricamente dónde una función alcanza sus valores más bajos. Su objetivo es converger hacia el mínimo de la función, utilizando aproximaciones numéricas en lugar de manipulaciones simbólicas.

Entrenamiento Durante el entrenamiento de una red neuronal artificial, se ajustan iterativamente los parámetros de entrada hasta encontrar los pesos sinápticos óptimos. Estos pesos permiten que la red se ajuste al mejor modelo posible, con las salidas estimadas aproximándose a los valores esperados.

Generación sintética Implica generar conjuntos de datos artificiales que replican las características estadísticas y patrones de los datos reales, sin contener información auténticas.

Normalización Proceso de ajustar los datos para que tengan una escala común o estandarizada, lo que facilita su comparación y análisis.

Overfitting Ocurre cuando la red neuronal adquiere un profundo conocimiento de los datos de entrenamiento, pero su rendimiento es deficiente en los datos de validación o en datos inéditos. Siempre buscamos evitar este comportamiento.

Pixel Unidad básica de una imagen digitalizada en pantalla a base de puntos de color o en escala de grises.

Retropropagación La retropropagación es un proceso mediante el cual se actualizan los pesos sinápticos en una red neuronal. Este algoritmo permite que la información del error fluya hacia atrás a través de la red, calculando el gradiente. A medida que se entrena la red, las neuronas de las capas intermedias se organizan para reconocer

distintas características del espacio total de entrada.

Tendencia Implica adaptar los datos a la forma de una curva, permitiendo su proyección según el comportamiento observado en los datos.

Underfitting Ocurre cuando la red neuronal no logra aprender adecuadamente de los datos de entrenamiento y, en general, presenta un rendimiento deficiente en todas las predicciones.

Lista de Acrónimos

ACI	: American Concrete Institute
ANN	: Artificial Neural Network
ASTM	: American Society for Testing and Materials
CNN	: Convolutional Neural Network
DL	: Deep Learning
GAN	: Generative Adversarial Network
IA	: Inteligencia Artificial
INACAL	: El Instituto Nacional de Calidad
ISO	: International Organization for Standardization
MATLAB	: Matrix of Laboratory
MEF	: Ministerio de Economía y Finanzas
ML	: Machine Learning
MTC	: Ministerio de Transportes y Comunicaciones.
NMSE	: Normalized mean square error
NTP	: Norma Técnicas Peruana
RNE	: Reglamento Nacional de Edificaciones
RNN	: Recurrent Neural Network
UAV	: unmanned aerial vehicles
UTM	: Universal Transversal Mercator

Símbolos

Z, z	Datos estandarizados
Y, y	Datos normalizado
U_t	Diferencia de operaciones
O_i	Valor observado para el dato i
χ^2	Estadístico de la prueba de bondad de ajuste
x	Entrada (input)
y	Salida (output)
w	Peso (weight)
b	Sesgo (bias)
σ	Función de activación
δ	Error (error)
η	Tasa de aprendizaje (learning rate)
J	Función de costo (cost function)
∇J	Gradiente de la función de costo
$*$	Operación de convolución
máx	Operación de max pooling
ReLU	Función de activación ReLU
softmax	Función de activación softmax
E_i	Valor esperado para el dato i
χ^2_{MN}	Estadístico de la prueba de bondad de ajuste de McNemar

Capítulo I

Planteamiento del Problema

1.1 Descripción del problema(mundial, país, región)

En la actualidad, la necesidad de poder inspeccionar y supervisar estructuras de concreto durante y después de su construcción luego en su fase de operación y mantenimiento del mismo, todavía se inspecciona predominantemente de forma manual. En términos sencillos, incluso en la actualidad, cuando se requiere inspeccionar una estructura en busca de daños, los ingenieros examinan manualmente todas las superficies, toman numerosas fotografías y anotan la ubicación de cualquier fisura y grieta en una ficha de inspección estandarizada. Luego, dedican horas en la oficina para organizar las fotos, descripciones y notas posteriormente crear un informe significativo. Este proceso resulta laborioso, costoso y subjetivo. Además, surgen preocupaciones de seguridad debido a partes de la estructura con acceso restringido y difícil alcance.

Desde el auge de grandes capacidades de almacenamiento y procesamiento de computo en gráficos a mediados del 2012, se está implementando nueva técnicas de evaluación e inspección de fisuras y grietas en estructuras de concreto armado a nivel mundial y regional. En China, se propuso un método para la evaluación de la severidad de las fisuras en concreto en las edificaciones importantes usando redes neuronales artificiales y análisis de imágenes. Se usó una red neuronal artificial con algoritmo de convolución, entrenada con un conjunto de 20000 imágenes de fisuras con diferentes niveles de severidad. Se obtuvo un coeficiente de correlación de 0.873 entre la severidad estimada por la red neuronal.

En Estados Unidos, se desarrolló un sistema para la identificación y cuantificación de fisuras en estructuras de concreto, usando redes neuronales artificiales y procesamiento de imágenes. Se usó una red neuronal multicapa, entrenada con un conjunto de 10000 imágenes de fisuras con diferentes anchos y orientaciones. Se obtuvo un error medio absoluto de 0.012 mm en la estimación del ancho de las fisuras y un error medio absoluto de 2.85° en la estimación de la

orientación de las fisuras.

En España, se aplicó una red neuronal artificial para la detección y clasificación de grietas en estructuras de concreto armado, usando imágenes digitales. Se utilizó una red neuronal convolucional con arquitectura AlexNet, entrenada con un conjunto de 6000 imágenes de grietas y no grietas. Se obtuvo una precisión del 98.33 % en la detección y una precisión del 97.5 % en la clasificación de grietas.

En Perú, se realizó una investigación para evaluar fisuras y grietas utilizando una aplicación web llamada Deep Crack. Se empleó una inspección y evaluación visual, acompañada de una ficha de inspección en puentes de concreto armado y mixto en la región de Lima. La red convolucional tenía como entrada una imagen mínima de 256x256 píxeles.

En la región de Ayacucho no hay investigaciones acerca del uso de Redes Neuronales para la evaluación de fisuras y grietas utilizando redes neuronales artificiales, sin embargo, hay algunas investigaciones referidas a la Ingeniería Civil.

En el estudio mencionado, se emplearon redes neuronales artificiales de base radial para estimar las precipitaciones en una cuenca hidrográfica local. Estas redes se basaron en datos obtenidos a través del proyecto TRMM (Tropical Rainfall Measuring Mission) y consideraron las condiciones geográficas, como altitud, latitud y longitud, junto con las mediciones de precipitación de las estaciones meteorológicas disponibles. (Canchari Gutiérrez, 2015)

En el estudio mencionado, se propone diseñar un modelo metaheurístico basado en redes neuronales artificiales de base radial para estimar los caudales de máxima avenida en cuencas urbanas y proyectos de drenaje pluvial. (Calderón Pillaca, 2016)

En la investigación presentada se demostró que un modelo de redes neuronales artificiales puede predecir con precisión el valor económico ambiental, influido directamente por las variables de ingreso en el distrito de Huamanga. (Arias Campos, 2022)

1.2 Delimitación del problema.

1.2.1 Espacial

La investigación se realizará en la provincia de Huamanga.

Región: Ayacucho.

Provincia: Huamanga

Puente Huatatas

Coordenada UTM : 587612.78 m E 8543406.82 m S

Puente Chacco

Coordenada UTM : 585961.73 m E 8551905.10 m S

1.2.2 Temporal

La investigación se desarrollará durante el año 2024.

1.2.3 Temática y unidad de análisis

La determinación de fisuras y grietas en estructuras de concreto.

1.3 Formulación del problema.

1.3.1 Problema general.

¿Qué modelo de Redes Neuronales Artificiales puede determinar fisuras y grietas, mediante procesamiento digital de imágenes tomadas en estructuras de concreto en la Provincia de Huamanga?

1.3.2 Problemas específicos.

- a) ¿Cómo influye la cantidad de capas y neuronas en el aprendizaje del modelo de una red neuronal artificial que detecta las fisuras y grietas en una estructura de concreto usando imágenes?
- b) ¿Cómo los pesos sinápticos de un modelo de Redes Neuronales Artificiales pueden mejorar el reconocimiento de fisuras y grietas en estructuras de concreto a partir de imágenes?
- c) ¿Es posible identificar la función de activación mas optima de un modelo de Redes Neuronales Artificiales para determinar las fisuras y grietas en estructuras de concreto a partir de imágenes?

1.4 Justificación e importancia.

La importancia de la tesis radica en ampliar y profundizar para mejorar la eficiencia y la efectividad de los procesos de inspección, evaluación y reparación de las estructuras de concreto, al proporcionar información precisa y oportuna sobre el estado, la ubicación de las fisuras y grietas. De esta manera, se puede optimizar el uso de los recursos y priorizar las intervenciones según el nivel de riesgo y urgencia.

El reconocimiento de fisuras y grietas en estructuras de concreto mediante el uso de redes neuronales artificiales puede generar beneficios sociales y económicos. Al detectar estos defectos en una etapa temprana, podemos realizar un mantenimiento preventivo y evitar que ocurran colapsos, asentamientos en las estructuras de concreto, lo que sería más costoso de repararlo y demandaría un mayor presupuesto.

El 5 de julio de 2023 se publicó la Ley N° 31814, Ley que promueve el uso de la inteligencia artificial en favor del desarrollo económico y social del país para promover el uso de la inteligencia artificial en el marco del proceso nacional de transformación digital y tecnológico del país.

Lo que se lograra en este trabajo es determinar e identificar las fisuras y grietas en estructuras de concreto. Asimismo, conduce y orienta a utilizar nuevas herramientas para la toma de decisiones que beneficien al prevención temprana de los elementos estructurales mas importantes de una estructuras de concreto.

1.5 Limitaciones de la investigación.

La limitación del problema encontrado es :

- Calidad y cantidad de datos de fisuras y grietas en la provincia de Ayacucho.
- La falta de acceso a grandes capacidades de computo para poder entrenar el modelo.
- La variabilidad de las condiciones ambientales para la toma de datos de buena calidad y sin ruido.
- Falta de equipos necesarios para la obtención de un sensor multiespectral; el cual mide la profundidad.
- Para este proyecto se limitara a la toma de datos de los puentes de Huatatas y Chacco.

1.6 Objetivo general.

Definir un modelo de Redes Neuronales Artificiales para determinar fisuras y grietas en estructuras de concreto armado en la provincia de Huamanga mediante el procesamiento digital de imágenes.

1.6.1 Objetivos específicos.

- a) Analizar la influencia de la cantidad de capas y neuronas en el aprendizaje del modelo de una red neuronal artificial que detecta las fisuras y grietas en una estructura de concreto armado usando imágenes.
- b) Evaluar el efecto de los pesos sinápticos de un modelo de Redes Neuronales Artificiales en el reconocimiento de fisuras y grietas en estructuras de concreto armado a partir de imágenes.
- c) Identificar la función de activación más óptima de un modelo de Redes Neuronales Artificiales para determinar las fisuras y grietas en estructuras de concreto armado a partir de imágenes.

Capítulo II

Marco Teórico.

2.1 Antecedentes.

2.1.1 Investigaciones internacionales

Según (Ahcene & Ouahabi, 2021) Presentan una nueva forma de identificar grietas en el concreto usando un análisis de diferentes muestras de concreto que se somete a distintas fuerzas. La ondícula que diseñaron procesa la imagen que obtuvieron con ultrasonido y la examina a varias escalas para encontrar grietas dentro y fuera del concreto. En su investigación crean un sistema automático que identifica el tipo de grieta usando redes neuronales convolucionales (CNN). Así mismo pueden controlar las grietas sin ver la superficie del concreto y encontrarlas antes de que se noten. Lo obtuvieron combinando dos técnicas importantes de análisis de datos: las ondículas y el aprendizaje profundo. En esta investigación el método utilizaron tiene una precisión muy alta, casi el 90%. Para medir el desempeño de las CNN que proponen, también usan una base de datos abierta, SDNET2018, para detectar grietas externas de forma automática.

(Liu & Yeoh, 2020) Utilizaron drones para inspeccionar las fachadas de los edificios, y detectar las grietas con regularidad. El método de inspección actual es muy costoso y lento, y tiene riesgos de seguridad, como caerse desde lo alto. Los drones con técnicas de visión artificial son una opción interesante para ver las grietas en las fachadas de los edificios altos. En su investigación para conseguir la inspección visual automática de grietas es que las imágenes se ven borrosas por el movimiento de los drones cuando las capturan. El movimiento borroso se debe a las vibraciones fuertes de la plataforma de los drones, y esto puede dificultar la detección de grietas. En este artículo, sugieren un modelo de desenfoque que usa el aprendizaje profundo y una red generativa adversarial (GAN) para resolver este problema. También, al reconocer una relación fuerte entre las imágenes de

grietas borrosas y claras, proponen la idea de usar una conexión de salto local. Haciendo una validación experimental del modelo de desenfoque que sugieren investigando cómo afectan las conexiones de salto al desenfoque. El modelo que sugieren también se compara con el modelo de desenfoque más moderno, y los resultados muestran que el modelo que puede conseguir mejoras importantes en el desempeño de desenfoque en cuanto a la estructura global y los detalles de las características en las imágenes de grietas.

En su investigación (Meng & Zhu, 2021) sobre inteligencia artificial, especialmente al combinar aprendizaje profundo y visión por computadora, se han obtenido mayores beneficios en la detección de grietas en concreto utilizando redes neuronales convolucionales (CNN) en comparación con los métodos tradicionales. Sin embargo, estos métodos de aprendizaje automático aún presentan algunas limitaciones, como imprecisión, debilidad, baja generalización y la necesidad de mejorar la precisión y velocidad de ejecución. En este artículo, se propone una red totalmente convolucional (FCN) modificada, más resistente y eficiente, adecuada para la monitorización e inspección estructural a largo plazo en comparación con otros enfoques. Además, se introdujeron innovaciones para aumentar la precisión del reconocimiento y la predicción. Destaca una capa de convolución de subpíxeles, que reduce significativamente el tiempo de muestreo. La factibilidad del método sugerido se verificó con una precisión global de reconocimiento del 97,92% y una mejora del 12% en eficiencia.

En su investigación (X. Chen & Du, 2021) utiliza un modelo de redes neuronales convolucionales para la detección de Las grietas en el concreto que causan muchos problemas de seguridad con el tiempo. Los métodos tradicionales de detección manual son caros, lentos y poco precisos. Por eso, se sugiere un método de reconocimiento que combina la red neuronal convolucional y la segmentación por clústeres. El método sugerido identifica con precisión la imagen de grietas en el concreto con un fondo complejo y aumenta la eficiencia de la identificación de grietas en el concreto. Los resultados del estudio indican que el método sugerido no solo distingue grietas y no grietas eficazmente, sino que también reconoce grietas en fondos complejos. El método sugerido tiene una precisión alta en el reconocimiento de grietas, que es al menos del 97,3% y hasta del 98,6%.

En su investigación (Hsu & Chang, 2021) presentan como la monitorización del estado de las estructuras es un campo muy importante y popular en la ingeniería estructural, porque

esta tecnología puede proteger las estructuras de los peligros naturales y extender su vida útil. Antes, la monitorización de la salud estructural se hacía principalmente con sensores de contacto para obtener respuestas estructurales y luego diagnosticar estructuras con estas mediciones. Por eso, este estudio propone un método basado en aprendizaje profundo que puede detectar y segmentar las grietas de concreto con mediciones sin contacto, como imágenes. Este método usa el aprendizaje profundo y la visión por ordenador para reconocer la presencia de grietas y hacer la segmentación posterior. Primero, se preparan los datos de entrenamiento con imágenes de superficies de concreto con o sin grietas, y se crean dos modelos avanzados como DeepLabv3+ y Mask R-CNN con los métodos de aprendizaje de transferencia y se entrenan con imágenes reales de grietas. Luego, los modelos entrenados pueden sacar características de las grietas y hacer una máscara (o sea, un mapa de probabilidad). Las grietas se reconocen y segmentan en las imágenes con la máscara predicha. Al final, el resultado por píxel se procesa para saber las propiedades geométricas de las grietas, como el largo y el ancho.

(Arbaoui & Ouahabi, 2021) presentan una nueva metodología para la detección y monitoreo de grietas en estructuras de concreto. Esta aproximación se basa en un análisis de multirresolución de una muestra o espécimen de material de concreto sometido a diferentes tipos de solicitaciones. La imagen obtenida mediante investigación ultrasónica y procesada con una pequeña onda personalizada se analiza a diferentes escalas para detectar grietas internas e inicio de grietas. El objetivo principal de este trabajo es proponer un esquema automático de identificación de tipos de grietas basado en redes neuronales convolucionales (CNN). En este contexto, la propagación de las grietas puede monitorearse sin acceso a la superficie de concreto, y el objetivo es detectarlas antes de que sean visibles. Esto se logra mediante la combinación de dos herramientas principales de análisis de datos: las ondaletas y el aprendizaje profundo. Este procedimiento original demuestra una alta precisión cercana al 90%. Para evaluar el rendimiento de las arquitecturas propuestas de CNN.

(B. Chen & Zhang, 2019) muestran una metodología para detectar eficazmente las grietas en la superficie de concreto, se utiliza el algoritmo OTSU basado en imágenes diferenciales. Primero, se aplica un filtro gaussiano a la imagen original para obtener una versión suavizada. Luego, se resta la imagen suavizada de la imagen original para obtener la

imagen diferencial. Según el algoritmo OTSU, se calcula el umbral óptimo en la imagen diferencial. Dado que las grietas características suelen ser de unos pocos píxeles y con valores de gris más bajos, solo se calculan los píxeles cuyos valores de gris son inferiores al valor medio de toda la imagen para obtener el mejor umbral. Finalmente, se elimina el ruido de fondo mediante reducción morfológica para obtener la imagen binaria de la grieta.

(Kaiwen & Xin, 2021) en su investigación utilizan vehículos aéreos no tripulados (UAVs) también llamados drones que se utilizan con frecuencia para la inspección visual periódica de envoltorios de edificios con el objetivo de detectar condiciones inseguras o daños vulnerables. Los profesionales de la inspección deben examinar manualmente las grandes cantidades de imágenes de alta resolución recopiladas por los UAVs para identificar anomalías o daños en las fachadas de los edificios, con fines de informes y reparaciones. Las tecnologías de visión por computadora y aprendizaje profundo han surgido como soluciones prometedoras para automatizar el proceso de inspección basado en imágenes. Sin embargo, para la detección de grietas en fachadas a partir de imágenes capturadas por UAVs, las soluciones de aprendizaje profundo existentes pueden no funcionar bien debido a los ruidos de fondo complicados causados por diferentes componentes y materiales de las fachadas. Con ese fin, este artículo propuso un método de aprendizaje profundo de dos pasos para la detección automatizada de grietas en fachadas a partir de imágenes capturadas por UAVs. En el primer paso, se diseñó y entrenó un modelo de red neuronal convolucional (CNN) con 26,177 imágenes para clasificar parches de 128×128 píxeles como grieta o no grieta. En el segundo paso, se entrenó un modelo de red neuronal U-Net con 2870 conjuntos de imágenes para segmentar los píxeles de grietas dentro de esos parches clasificados como grietas. Los resultados experimentales muestran un alto rendimiento del 94% y 96% de precisión, 94% y 95% de recall, y 94% y 96% de puntajes F1 para el modelo CNN y el modelo U-Net, respectivamente. Los resultados experimentales demostraron que el método de dos pasos puede mejorar la confiabilidad y eficiencia en la detección y diferenciación de grietas en fachadas, incluso en presencia de ruidos complicados.

2.1.2 Investigaciones nacionales

En la tesis de (Maguiña Asis & Pascacio Zarzosa, 2021) Se utiliza una herramienta web basada en una red neuronal llamada Deep Crack para realizar tres pasos importantes. Primero, se carga la imagen que se desea examinar, teniendo en cuenta que cumpla con las especificaciones del código, como el formato y el tamaño. Segundo, se ajusta el tamaño de la imagen para que se adapte mejor a la matriz de la red convolucional, lo que implica que la imagen tenga una calidad mínima de 256x256 píxeles. Tercero, se elige la opción de ajuste de tamaño, ya que se trata de detectar grietas gruesas. Al final, se obtienen dos tipos de resultados. El primero es una imagen en blanco y negro que muestra el procesamiento y la identificación de las áreas agrietadas y desgastadas. El segundo es una versión mejorada, que muestra el escaneo de las grietas sobre la imagen original.

2.2 Bases teóricas

En este capítulo, exploraremos aspectos relacionados con la metodología empleada en el levantamiento fotogramétrico, el procesamiento de imágenes y el entrenamiento de una red neuronal para detectar fisuras y grietas.

2.2.1 Patología estructural

En el ámbito de la construcción, la patología estructural se dedica al estudio e identificación de las “enfermedades, síntomas y causas” que pueden afectar a las estructuras de concreto. Estas lesiones o deterioros pueden ser de naturaleza física (como humedad, suciedad o erosión), mecánica (grietas, fisuras o deformaciones) o química (oxidación, corrosión o carbonatación). Los problemas patológicos se manifiestan externamente, lo que significa que se pueden observar visualmente.

2.2.2 Procesamiento de Imágenes


El procesamiento de imágenes engloba un conjunto de técnicas y algoritmos matemáticos utilizados para manipular, analizar y mejorar imágenes digitales. Mediante programas informáticos, se aplican operaciones como filtrado, segmentación, restauración, reconocimiento de patrones y compresión de imágenes. El objetivo principal es mejorar la calidad de las imágenes al eliminar ruido, distorsiones y otros artefactos que afectan la

interpretación visual. Además, se emplea para tareas de análisis, como detección de bordes, medición de objetos e identificación de características específicas en las imágenes.

2.2.3 Redes Neuronales Artificiales

Una red neuronal artificial (ANN) se inspira en el modelo del cerebro biológico. Sus unidades, llamadas nodos, se organizan en múltiples capas que operan en paralelo. Cuando una neurona artificial recibe una señal numérica, la procesa y envía una señal a otras neuronas conectadas. De manera similar al cerebro humano, este proceso de refuerzo neuronal conduce a un mejor reconocimiento de patrones, adquisición de experiencia y aprendizaje general.

Figura 1 Relación entre la Inteligencia Artificial, Machine Learning Deep Learning y las Redes Neuronales Artificiales.



Nota: Mapa conceptual entre Inteligencia Artificial, Machine Learning y Deep Learning

2.3 Marco conceptual.

2.3.1 Fisuras y grietas

Una fisura y una grieta es una abertura longitudinal que afecta solo la capa exterior del elemento de concreto. Su ancho suele ser menor a 1 mm en cambio una grieta su ancho suele ser mayor a 1mm. Las fisuras pueden aparecer por cambios de humedad, temperatura o estado tensional de las armaduras. Las fisuras no comprometen la resistencia de la estructura, pero pueden facilitar el ingreso de agentes nocivos que corroen el acero de refuerzo. En cambio las grietas pueden aparecer por movimientos del suelo, reparto defectuoso de las cargas, sobrecargas, variaciones térmicas, entre otros factores. Las grietas sí comprometen la resistencia de la estructura, y requieren de una reparación urgente.

2.3.1.1 Clasificación de las fisuras en concreto atendiendo a su tamaño

Cuando alguna causa desencadena la fisuración del concreto, de acuerdo al libro Rehabilitación y Mantenimiento de Estructuras de Concreto existen tres tipos de fisuras atendiendo a su tamaño:

- **Microfisuras:** “Su espesor es inferior a 0,05 mm (no se aprecian a simple vista) y generalmente no suelen tener gran importancia.”(Helene & Pereira, 2007)
- **Fisuras:** “Su espesor está entre 0,1 mm y 0,2 mm y las podemos percibir de forma visual. Debemos prestar especial atención a estas fisuras en ambientes agresivos, ya que pueden causar la corrosión de las armaduras.”(Helene & Pereira, 2007)
- **Macrofisuras:** “su espesor es mayor 0,2 mm. Cuando nos encontramos un elemento de concreto armado con macrofisuras habrá que tomar medidas, ya que pueden suponer un riesgo para la estabilidad de las estructura.”(Helene & Pereira, 2007)

Según el código ACI 224.R-01, se establece un ancho máximo para las fisuras y grietas en estructuras de concreto sometidas a flexión, considerando diversas condiciones climáticas y agresividad química.

Tabla 1 *Ancho máximo en estructuras sometidas a flexión.*

CONDICIÓN DE EXPOSICIÓN	ANCHO DE FISURA	
	pulg	mm
Aire seco o membrana protectora	0,016.	0,41
Humedad, aire húmedo, suelo	0,012	0,30
Químicos para deshielo	0,007	0,18
Agua de mar, zona de salpique, ciclo húmedo y seco	0,006	0,15
Estructuras de retención de agua*	0,004	0,10

Fuente: Obtenido de ACI 224.R-01 224 (2007)

2.3.1.2 Clasificación de las fisuras en concreto según su origen o causa

Existen varios tipos de fisuras y grietas en el concreto, según su tamaño, forma, origen y consecuencia. Algunos de los tipos más comunes son:

- **Asentamiento de plástico:** Son fisuras que ocurren cuando el concreto se asienta por su propio peso, debido a una mala compactación o a una diferencia de altura entre zonas adyacentes. Suelen ser verticales u oblicuas, y se localizan cerca de las esquinas o los bordes del elemento de concreto.
- **Contracción plástica:** Son fisuras superficiales que se producen cuando el concreto se seca demasiado rápido antes de fraguar, debido a una alta tasa de evaporación. Suelen ser paralelas o diagonales a las aristas del elemento de concreto.
- **Contracción térmica temprana:** Son fisuras que se forman cuando el concreto pierde humedad después de fraguar, debido a la retracción por secado. Suelen ser horizontales o verticales, y se distribuyen de forma irregular en el elemento de concreto.
- **Contracción por secado a largo plazo:** Son las lesiones causadas principalmente por agentes biológicos en este caso microorganismos que al hacer contacto con el material, aire y agua causan mucho daño.
- **Resquebrajadura:** Son fisuras que dibuja finas grietas en la superficie del concreto, haciéndolo parecer envejecido.
- **Corrosión de la armadura:** Son fisuras que se generan cuando el acero de refuerzo se corroe por la acción de agentes externos, como el agua, el cloruro, el sulfato, etc. Suelen ser ramificadas y estrelladas, y se concentran alrededor de las barras de acero.

- **Reacción álcali-silice:** Son fisuras que se originan cuando el concreto se expande por cambios de reacciones químicas internas, como la alcali-agregado. Suelen ser anchas y profundas, y se extienden a lo largo del elemento de concreto.

Figura 2 Clasificación de las fisuras en concreto según su origen o causa.



Nota: Elaboración Propia

Según (Day & Clarke, 2003) La fisuración plástica y la fisuración térmica del concreto, que se producen por diferentes causas y en diferentes momentos. La fisuración plástica se debe al exudación y a la retracción del concreto fresco, mientras que la fisuración térmica se debe a los cambios de temperatura del concreto endurecido. El párrafo explica los factores que influyen en el mecanismo y el patrón de las fisuras, así como los efectos a largo plazo de la retracción por secado.

Según (Hammer, 2006) Los dos tipos de fisuración temprana que pueden afectar al concreto: la fisuración por retracción plástica y la fisuración térmica. Ambas dependen de factores como la absorción de agua, el calor de hidratación, la capacidad calorífica, la contracción autógena y el módulo de elasticidad del concreto. Analiza cómo estos factores influyen en el riesgo de fisuración en las diferentes fases del proceso de fraguado y endurecimiento del concreto. El texto concluye que el uso de LWA(agregados finos) puede tener efectos positivos o negativos sobre el riesgo de fisuración, dependiendo de la fase y del grado de humedad del LWA.

Según (Banthia & Gupta, 2009) Las proporciones de la mezcla afectan al agrietamiento por contracción plástica en reparaciones y recubrimientos cementosos. El estudio usa un método de superposición adherida y analiza varias variables, como la relación agua-cemento,

la relación árido-cemento, el contenido de cenizas volantes y el uso de un aditivo reductor de la contracción. El texto presenta los resultados del estudio, que muestran cómo estas variables influyen en el ancho, el área y el tiempo de las grietas. El texto también muestra el efecto del aire acondicionado como contención interna y el efecto de las cenizas volantes como reductor de la contracción.

Según (Sasaki & Fujibayashi, 2013) La causa de la rotura de los aceros de refuerzo en estructuras antiguas afectadas por la reacción de álcali-sílice. El estudio identifica cuatro factores que contribuyen a la rotura: la tensión residual de tracción, el endurecimiento por trabajo o el envejecimiento por deformación, la corrosión y la fragilización por hidrógeno, y la expansión por la reacción de álcali-sílice. El texto también propone medidas de mantenimiento para prevenir la rotura de los aceros de refuerzo.

2.3.2 Modelo de Redes Neuronales Artificiales


El Deep Learning es una rama del aprendizaje automático que se basa en redes neuronales artificiales con múltiples capas, permitiendo el aprendizaje de representaciones de datos de forma jerárquica y automática, como se muestra en la figura 1. En el contexto de la detección de grietas en elementos de estructuras de concreto armado, el Deep Learning se utiliza para extraer características relevantes de las imágenes de los elementos estructurales de concreto y aprender patrones que indiquen la presencia de grietas. El aprendizaje profundo es un subconjunto de los métodos de aprendizaje automático basado en redes neuronales con aprendizaje de representación. La palabra “profundo” se refiere al uso de múltiples capas en la red. Estos algoritmos se inspiran en el funcionamiento de las redes neuronales en el cerebro humano, pero no pretenden modelar exactamente cómo funciona el cerebro. En cambio, se consideran modelos de baja calidad para ese propósito.

2.3.2.1 La neurona biológica

Una neurona biológica es una célula especializada que forma parte del sistema nervioso en seres humanos y otros organismos pluricelulares. Estas neuronas desempeñan un papel fundamental al procesar y transmitir información mediante señales eléctricas y químicas. Su estructura incluye el cuerpo celular (soma), las dendritas, el axón, la mielina y los botones terminales. Las dendritas captan señales de otras neuronas o del entorno, el soma integra las señales entrantes y decide si transmitir una señal de salida, y el axón envía impulsos eléctricos

a otras neuronas o células. En los botones terminales, los neurotransmisores se liberan para comunicarse con la siguiente célula.

Figura 3 Neurona Biológica.



Nota: Adaptado de Salinas

2.3.2.2 La Neurona Artificial

Una neurona artificial es un componente fundamental en redes neuronales artificiales (ANNs) utilizadas en aprendizaje automático y procesamiento de información. A diferencia de las neuronas biológicas, las neuronas artificiales son unidades computacionales diseñadas para procesar datos y realizar cálculos en sistemas informáticos.


Según (Araya Pizarro, 2022) desde una perspectiva biológica, los neurocientíficos se enfocan en comprender el funcionamiento esencial del cerebro, lo que permite crear modelos representativos del mismo. Las neuronas se consideran los bloques de construcción esenciales del cerebro, ya que transmiten impulsos eléctricos que resultan en el procesamiento de información. Por otro lado, desde una perspectiva computacional, los sistemas de conexión (CS) describen el funcionamiento cerebral mediante simulaciones en silicio, intentando emular comportamientos inteligentes. Este objetivo se logra mediante las redes neuronales artificiales, que procesan datos rápidamente, aprenden patrones no lineales entre la entrada y la salida, y pueden generalizarse para datos no vistos previamente. Una representación matemática del funcionamiento básico de una neurona artificial se muestra

en la siguiente expresión de la ecuación 2.1 .

$$Z_j = \sum w_{ij}x_j - \theta_i \quad (2.1)$$

Siendo Z_j el Output, x el vector Input, w el vector de pesos y el umbral. Normalmente la señal Output Z_j suele ser procesada por una función de activación f para producir la señal de salida de la neurona Y_i .

Figura 4 Modelo de una red neuronal artificial.



Nota: Adaptado de Data Science Research Perú

2.3.2.3 Elementos básicos de una red neuronal

Una red neuronal artificial está compuesta por varios elementos clave que trabajan juntos para procesar información y realizar tareas específicas. Se muestran los componentes fundamentales de una red neuronal artificial:

A) Capa de entrada o Input

La capa de entrada en una red neuronal es análoga a nuestros sentidos que proporcionan información al cerebro. Aquí, los datos ingresan a la red, y si la entrada es una imagen, se representan como píxeles convertidos en valores basados en la escala de grises. Primero, ajustamos los datos que se ingresan en la red mediante la capa de entrada. Este proceso de normalización garantiza que todas las características estén en una escala estandarizada.

Normalización Min-Max:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

Estandarización:

$$x' = \frac{x - \mu}{\sigma}$$

Los datos normalizados se introducen en la red a través de la capa de entrada. En esta capa, los datos se representan como un vector $\mathbf{X}$.

Vector de Entrada:

$$\mathbf{X} = [x_1, x_2, \dots, x_n]$$

Donde: - x_i son los valores de entrada normalizados. - n es el número de características de entrada.

B) Capas ocultas o Hiddenlayers

En las capas ocultas de una red neuronal, es donde sucede la “magia”. Aquí, los datos de la capa de entrada se procesan y transforman. En la mayoría de los casos, encontramos varias capas ocultas en la red, y estas permiten que la red aprenda patrones complejos y representaciones más abstractas de los datos.

En las capas ocultas, cada neurona recibe entradas, las pondera y aplica una función de activación. La salida de una neurona se calcula como:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Donde:

y es la salida de la neurona.

f es la función de activación.

w_i son los pesos.

x_i son las entradas.

b es el sesgo.

C) Funciones de activación

”La función de activación, también conocida como función de transferencia, establece la relación entre las entradas y salidas de un nodo en una red neuronal. Su introducción de no linealidad es crucial para aplicaciones efectivas de redes neuronales”.(Zhang & Patuwo,

1998)

En resumen, cualquier función diferenciable puede considerarse como una función de activación en teoría. Sin embargo, en la práctica, se utilizan solo unas pocas funciones de activación que cumplen con ciertas propiedades deseables, como ser acotadas, monótonamente crecientes y diferenciables. A continuación, se presentan las funciones de activación más comunes.

- **Funciones lineales:** Son aquellos que dan una salida lineal

$$f(x) = x$$

$$f(x) = \begin{cases} -1 & \text{si } x \leq -1 \\ x & \text{si } -1 < x < 1 \\ 1 & \text{si } x \geq 1 \end{cases}$$

- **Funciones escalón:** Las funciones de activación binaria generan una salida que depende de si el valor de entrada está por encima o por debajo de un umbral específico. En otras palabras, producen una respuesta “encendida” o “apagada” según la comparación con el umbral.

$$f(x) = \text{sgn}(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

- **Funciones sigmoidales:** Las funciones de activación sigmoidales son aquellas que, siendo monótonas y acotadas, proporcionan una salida gradual no lineal en función de las entradas. Las más populares incluyen la sigmoide y otras similares:

La función logística [0 a 1]:

$$f(x) = \frac{1}{1+e^{-x}}$$

La función tangente hiperbólica de [-1 a 1]:







$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- **Función seno o coseno:**

$$f(x) = \text{sen}(x) ; f(x) = \text{cos}(x)$$

A pesar de que existen otras funciones de activación, las más comunes son la sigmoide y la tangente hiperbólica. Estas funciones no solo proporcionan resultados aceptables, sino que también son computacionalmente eficientes debido a que su derivada está relacionada con la función en sí misma.(Socha & Ortiz, 2005).

Figura 5 funciones de activación.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq l \\ +1, & \text{si } x > l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	


Nota: Adaptado de (Socha y Ortiz, 2005)

D) Capa de salida u Output

La capa de salida proporciona el resultado final después del procesamiento. Aquí, se realiza una predicción o clasificación basada en los datos procesados. Por ejemplo, en una red de clasificación de imágenes, la capa de salida podría indicar si la imagen contiene un gato o un perro.

Puede apreciarse un esquema de una red neuronal artificial de tres capas con conexiones hacia delante:

Figura 6 Modelo de una red neuronal artificial multicapa.



Nota: Adaptado de Data Science Research Perú

La misma está constituida por conjunto de conexiones o pesos sinápticos entre neuronas (interconexiones) y arregladas en tres capas (este último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas.

E) Retropropagación

La retropropagación es un algoritmo utilizado para minimizar la función de pérdida en una red neuronal. Este proceso implica los siguientes pasos:

Cálculo del Error

Primero, se calcula el error entre la salida predicha ($\hat{y}$) y la salida real (y). Este error se mide utilizando una función de pérdida.

Función de Pérdida (MSE para regresión)

La función de pérdida más comúnmente utilizada para problemas de regresión es el Error Cuadrático Medio (MSE):

$$L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Donde:

L es la función de pérdida.

n es el número de muestras.

y_i es el valor real de la i -ésima muestra.

$\hat{y}_i$ es el valor predicho de la i -ésima muestra.

Propagación del Error hacia Atrás

El error calculado se retropropaga a través de la red, comenzando desde la capa de salida y avanzando hacia las capas ocultas y la capa de entrada. Durante este proceso, se determinan los gradientes de la función de pérdida con respecto a cada peso en la red.

$$\frac{\partial L}{\partial w_{ij}} = \frac{\partial L}{\partial y_j} \cdot \frac{\partial y_j}{\partial z_j} \cdot \frac{\partial z_j}{\partial w_{ij}}$$

Donde:

z_j es la entrada neta a la neurona j .

Actualización de Pesos

Los pesos se actualizan utilizando la siguiente fórmula:

$$w_{ij} = w_{ij} - \eta \frac{\partial L}{\partial w_{ij}}$$

Donde:

w_{ij} es el peso entre la neurona i y la neurona j .

η es la tasa de aprendizaje.

$\frac{\partial L}{\partial w_{ij}}$ es el gradiente de la función de pérdida con respecto al peso w_{ij} .

Este proceso se repite iterativamente para minimizar el error y mejorar el rendimiento de la red.

2.3.2.4 Mecanismos de aprendizaje

A) Aprendizaje supervisado

Es una subcategoría del machine learning y la inteligencia artificial. En este enfoque, se utilizan conjuntos de datos etiquetados para entrenar algoritmos que clasifican datos o predicen resultados con precisión. Se proporcionan ejemplos de entrada junto con las salidas deseadas, permitiendo que el modelo aprenda a producir los resultados correctos. Los algoritmos supervisados se aplican a problemas de clasificación (donde se asignan datos

a categorías específicas) y regresión (para entender relaciones entre variables). Algunos ejemplos comunes de algoritmos supervisados incluyen redes neuronales, máquinas de vectores de soporte (SVM) y regresión lineal.

B) Aprendizaje no supervisado o autoorganizado

Es una técnica en la que los modelos no requieren un conjunto de datos de entrenamiento etiquetado. En lugar de eso, los modelos descubren patrones ocultos e ideas por sí mismos a partir de los datos proporcionados. En resumen, se basa en conjuntos de datos no etiquetados y utiliza algoritmos para analizar y agrupar estos datos sin intervención humana. Algunas aplicaciones comunes incluyen el análisis exploratorio de datos, estrategias de venta cruzada, segmentación de clientes y reconocimiento de imágenes.

Figura 7 Relación de aprendizaje supervisado, no supervisado y aprendizaje por refuerzo.



Nota: Adaptado de Microsoft courses.

C) Aprendizaje por Refuerzo


Es una técnica en la cual la máquina guía su propio aprendizaje mediante recompensas y castigos. En resumen, se trata de un sistema de instrucción autónomo cuyo camino se determina según sus aciertos y errores. A diferencia de los enfoques supervisados y no supervisados, el aprendizaje por refuerzo se aplica en escenarios más amplios y cambiantes, como la toma de decisiones en entornos complejos.

2.3.2.5 Tipos de redes neuronales artificiales


Las redes neuronales artificiales (RNA) son modelos computacionales inspirados en la estructura y el funcionamiento de las redes neuronales biológicas del cerebro humano. Las RNA están formadas por nodos interconectados, o "neuronas", que procesan y transmiten información.(Montaño, 2002). Existen varios tipos de RNA, cada uno de ellos diseñado para tareas y tipos de datos específicos.Las siguientes arquitecturas de redes neuronales artificiales son las mas utilizadas:

A) Red neuronal Feed forward(FFNN) y los Perceptrones(P)

Se trata de una red neuronal que procesa la información en ambas direcciones, desde la entrada hasta la salida. Las redes neuronales suelen organizarse en capas, donde cada capa contiene celdas de entrada, ocultas o de salida en paralelo. Es importante destacar que una capa individual no tiene conexiones, y, en general, las capas adyacentes están completamente interconectadas(cada neurona forma una capa a cada neurona a otra capa). Una red neuronal feedforward (FFNN) simple y práctica consta de dos celdas de entrada y una celda de salida. Esta configuración se utiliza para modelar puertas lógicas. Por lo general, las FFNN se entrenan mediante retropropagación, que implica proporcionar a la red conjuntos de datos emparejados de "entrada" y "salida deseada". Este proceso se denomina aprendizaje supervisado, a diferencia del aprendizaje no supervisado, donde solo proporcionamos información y permitimos que la red complete los vacíos. El error que se propaga hacia atrás suele ser una variación entre la entrada y la salida. Aunque teóricamente una red con suficientes neuronas ocultas puede modelar cualquier relación entre entrada y salida, en la práctica su uso es más limitado. Sin embargo, estas redes a menudo se combinan con otras para formar arquitecturas más complejas "El perceptrón es un modelo probabilístico para el almacenamiento y la organización de la información de la red neuronal artificial". (Rosenblantt, 1958)

Figura 8 Red neuronal Monocapa – Perceptrón simple.


Nota: Adaptado de (Socha y Ortiz, 2005)

Figura 9 Perceptrón multicapa.

Nota: Adaptado de (Socha y Ortiz, 2005)

B) Red neuronal Convolutiva (CNN)


Las redes neuronales convolucionales (CNN) son diferentes de la mayoría de las otras redes. Se diseñaron principalmente para el procesamiento de imágenes, pero también se pueden aplicar a otros tipos de entrada, como el audio. Un caso de uso común para las CNN es la clasificación de imágenes: cuando se les proporciona una imagen, la red puede generar la etiqueta “gato” si la imagen muestra un gato, o “perro” si muestra un perro. Las redes neuronales convolucionales tienden a comenzar con un “escáner” de entrada que no está destinado a analizar todos los datos de entrenamiento a la vez. (Lecun & Bottou, 1998)

Figura 10 Red neuronal Convolutiva.

Nota: Adaptado de AIHubs

C) Red neuronal recurrente (RNN)

Las redes neuronales recurrentes (RNN) son un tipo de red neuronal artificial especializado en procesar datos secuenciales o series temporales. Estos algoritmos de aprendizaje profundo se utilizan comúnmente para resolver problemas relacionados con el orden o el tiempo, como la traducción de idiomas, el reconocimiento de voz y la generación de subtítulos para imágenes. A diferencia de las redes neuronales profundas tradicionales, que asumen que las entradas y salidas son independientes entre sí, las RNN incorporan una “memoria”. Esto significa que obtienen información de entradas anteriores para influir en las salidas actuales. Sin embargo, las RNN enfrentan el problema del gradiente de desaparición o explosión, donde la información se pierde rápidamente con el tiempo, similar a cómo las FFNN profundas también pueden perder información en capas profundas. (Elman, 1990)

Figura 11 Red neuronal Recurrente.


Nota: Adaptado de MLtutors AI.

D) Las redes de memoria a largo/corto plazo (LSTM)

Estos modelos están principalmente inspirados en circuitos electrónicos, más que en procesos biológicos. Cada neurona consta de una unidad de memoria y tres puertas: entrada, salida

y olvido. Estas puertas desempeñan un papel crucial al controlar el flujo de información. La puerta de entrada regula cuánta información de la capa anterior se almacena en la celda, mientras que la capa de salida determina qué parte de la siguiente capa tiene acceso al estado de esta celda. (Hochreiter & Schmidhuber, 1997)

Figura 12 Modelo de una red neuronal de memoria a largo plazo LSTM.



Nota: Arquitectura de una red de memoria a largo plazo.

E) Las unidades recurrentes cerradas (GRU)

Las redes neuronales GRU (Gated Recurrent Unit) son una variante ligera de las LSTM. A diferencia de las LSTM, las GRU tienen una puerta menos y están conectadas de manera diferente. En lugar de las puertas de entrada, salida y olvido, las GRU cuentan con una única puerta de actualización. Esta puerta determina cuánta información se conserva del estado anterior y cuánta información se permite ingresar desde la capa anterior. Además, la puerta de reinicio en las GRU funciona de manera similar a la puerta de olvido en las LSTM, aunque su ubicación es ligeramente diferente. (Chung & Gulcehre, 2014)

F) Los autocodificadores (AE)


Los autocodificadores (AE) son similares a las redes neuronales feedforward (FFNN), aunque se utilizan de manera diferente en lugar de representar una arquitectura fundamentalmente distinta. La idea central detrás de los autocodificadores es codificar información automáticamente, similar a la compresión más que al cifrado, de ahí su nombre. En términos de estructura, toda la red se asemeja a una forma de reloj de arena, con capas ocultas más pequeñas que las capas de entrada y salida. Los autocodificadores también son siempre

simétricos alrededor de la(s) capa(s) intermedia(s) (una o dos, dependiendo de una cantidad par o impar de capas). La(s) capa(s) más pequeña(s) está(n) casi siempre en el medio, el lugar donde la información está más comprimida (el cuello de botella de la red). Todo lo que llega hasta el medio se llama la parte de codificación, todo lo que está después del medio la decodificación y el medio (sorpresa) el código. Se puede entrenar utilizando la retropropagación alimentando la entrada y configurando el error para que sea la diferencia entre la entrada y lo que salió. Los AE también se pueden construir simétricamente cuando se trata de pesos, por lo que los pesos de codificación son los mismos que los pesos de decodificación.(Bourlard & Kamp, 1988)

G) Las redes generativas adversarias (GAN)

Las GAN consisten en dos redes cualesquiera (aunque a menudo son una combinación de FF y CNN), una de las cuales tiene la tarea de generar contenido y la otra tiene que juzgar el contenido. La red discriminante recibe datos de entrenamiento o contenido generado de la red generativa. La eficacia del discriminador radica en su capacidad para predecir correctamente la fuente de los datos utilizados como parte del error para la red generadora. Esto crea una dinámica competitiva: el discriminador mejora en la distinción entre datos reales y generados, mientras que el generador aprende a ser menos predecible para el discriminador. Esta estrategia funciona bien, en parte, porque incluso patrones complejos similares al ruido eventualmente se vuelven predecibles. Sin embargo, el contenido generado con características similares a los datos de entrada es más difícil de distinguir.(Goodfellow, 2014)

Figura 13 Modelo de una Red Generativa Adversaria.



Nota: Adaptado de Google DeepMind.


H) Mapas autoorganizados(SOM)

Los mapas autoorganizados son diferentes de otras redes neuronales artificiales, ya que utilizan una función de vecindad para preservar las propiedades topológicas del espacio de entrada. Estos mapas se utilizan para visualizar vistas de baja dimensión de datos de alta dimensión, de manera similar a un escalado multidimensional. El modelo fue descrito por primera vez por el profesor finlandés Teuvo Kohonen, y a veces se les llama redes o mapas de Kohonen. Operan en dos modos: entrenamiento (construcción del mapa usando ejemplos entrenantes) y mapeo (clasificación de nuevas entradas). (Kohonen, 1982)

I) Redes de base radial (RBF)

son un tipo de redes neuronales artificiales que utilizan funciones de base radial como funciones de activación. Se caracterizan por tener una estructura de tres capas: una capa de entrada, una capa oculta con funciones de base radial y una capa de salida que realiza una combinación lineal de las activaciones de las neuronas ocultas. (Broomhead & Lowe, 1988)

Figura 14 Red de base radial.




Nota: Adaptado de Khan Academy

J) Las redes de atención (AN) o también llamado Transformers

Las redes de atención pueden considerarse una categoría de arquitecturas que incluye el famoso modelo Transformer. Estas redes utilizan un mecanismo de atención para abordar la descomposición de la información almacenando estados anteriores de la red por separado y ajustando la atención entre ellos. Los estados ocultos de cada iteración en las capas de codificación se almacenan en celdas de memoria. Las capas de decodificación están

conectadas a las capas de codificación y también reciben datos filtrados por un contexto de atención desde las celdas de memoria. Este proceso de filtrado agrega contexto a las capas de decodificación, lo que enfatiza la importancia de características específicas. La red de atención, que produce este contexto, se entrena utilizando la señal de error de la salida de la capa de decodificación. Además, el contexto de atención se puede visualizar, lo que proporciona información valiosa sobre cómo las características de entrada se relacionan con las características de salida. (Jaderberg & Simonyan, 2016)

Figura 15 Modelo de una Red Neuronal Transformers.



Nota: Arquitectura de una red neuronal transformer adaptado de Google Deepmind.

2.3.3 Modelo de Redes Neuronales convolucionales

2.3.3.1 Imagen de Entrada

El conjunto de datos incluye imágenes de superficie de concreto capturadas in situ. Estas imágenes se preprocesan mediante técnicas de escalado, normalización y augmentación para mejorar la robustez del modelo. Las imágenes se representan como matrices tridimensionales

de tamaño $H \times W \times C$.

$$\mathbf{I} \in \mathbb{R}^{H \times W \times C}$$

Donde:

H es la altura.

W es la anchura.

C es el número de canales de color (normalmente 3 para RGB).


2.3.3.2 Convolucion

Las convoluciones bidimensionales se emplean en el procesamiento de imágenes para aplicar filtros, como encontrar parches específicos o detectar características. En las redes neuronales convolucionales (CNN), las capas convolucionales filtran un tensor de entrada utilizando una pequeña ventana llamada kernel. Este kernel define qué características se filtrarán durante la operación de convolución y generará una respuesta significativa cuando encuentre lo que se busca. La operación de convolución es una operación lineal, representada por un asterisco, que fusiona dos señales u operaciones como se muestra en la ecuación:

$$f[x, y] * g[x, y] = \sum_{n_1=-\infty}^{\infty} \sum_{n_2=-\infty}^{\infty} f[n_1, n_2] \cdot g[x - n_1, y - n_2]$$

La siguiente figura muestra el resultado de convolucionar una imagen con un núcleo particular llamado filtro Sobel que es bueno para encontrar bordes en una imagen:

Figura 16 Convolucion de una imagen.



Nota: Adaptado de Hands-On Convolutional Neural Networks with TensorFlow

En una capa de convolución, los parámetros aprendidos son los pesos del núcleo. Durante el entrenamiento de una red neuronal convolucional (CNN), estos valores se ajustan

automáticamente para extraer la información relevante para la tarea en cuestión. A diferencia de las redes neuronales tradicionales, donde convertiríamos los datos de entrada en un vector unidimensional, las capas de convolución preservan la información espacial importante. Cada píxel no tiene un parámetro por neurona, lo que evita una explosión en el número de parámetros. En resumen, las capas de convolución utilizan núcleos pequeños e independientes del tamaño de la entrada, lo que reduce significativamente la cantidad de parámetros en comparación con las capas densas tradicionales.

2.3.3.3 Filtros convolucionales

Una de las razones para introducir las redes neuronales convolucionales (CNN) fue abordar la alta dimensionalidad de los datos de imágenes. Si consideramos una imagen en color con 103×103 píxeles, cada uno representando intensidades de rojo, verde y azul, una arquitectura totalmente conectada requeriría una cantidad masiva de parámetros. Por ejemplo, si la primera capa oculta tuviera 1.000 unidades, ya tendríamos 3×10^9 pesos solo en esa capa. Además, una red así tendría que aprender invarianzas y ambigüedades a través de ejemplos, lo que requeriría enormes conjuntos de datos. Sin embargo, diseñando arquitecturas que incorporen nuestro sesgo inductivo sobre la estructura de las imágenes, podemos reducir drásticamente los requisitos de datos y mejorar la generalización, especialmente en relación con las simetrías espaciales. Para aprovechar la estructura bidimensional de las imágenes y crear sesgos inductivos, utilizamos cuatro conceptos clave: jerarquía, localidad, ambigüedad e invariancia.

Imaginemos la tarea de detectar caras en imágenes. Existe una estructura jerárquica natural porque una imagen puede contener múltiples caras, y cada cara incluye elementos como los ojos. A su vez, cada ojo tiene una estructura, como el iris, que a su vez se compone de bordes. En el nivel más básico de la jerarquía, un nodo de una red neuronal podría detectar características como bordes utilizando información local de una pequeña región de la imagen. Por lo tanto, solo necesitaría examinar un pequeño subconjunto de píxeles de la imagen. Las estructuras más complejas en niveles superiores de la jerarquía se detectan combinando múltiples características extraídas en niveles anteriores. Un aspecto clave es que, aunque deseamos incorporar la idea general de jerarquía en el modelo, preferimos que los detalles específicos, como el tipo de características extraídas en cada nivel, se aprendan automáticamente a partir de los datos, en lugar de codificarlos manualmente. Los modelos jerárquicos encajan de manera natural en el marco del aprendizaje profundo, que permite

extraer conceptos complejos a partir de datos brutos mediante una sucesión de “capas” de procesamiento, posiblemente numerosas, en las que todo el sistema se entrena de principio a fin.

La primera capa del modelo aplica convoluciones para extraer características de bajo nivel, como bordes y texturas. La operación de convolución para una entrada $\mathbf{I}$ y un filtro $\mathbf{K}$ se define como:

$$(\mathbf{I} * \mathbf{K})(i, j) = \sum_m \sum_n \mathbf{I}(i + m, j + n) \cdot \mathbf{K}(m, n)$$

Aquí, $\mathbf{K}$ es un kernel de convolución usualmente de tamaño 3×3 . Este proceso se repite en varias capas convolucionales, seguidas de capas de activación no lineal como ReLU (Rectified Linear Unit):

$$\text{ReLU}(x) = \max(0, x)$$


2.3.3.4 Detectores de características

Para simplificar, centrémonos en imágenes en escala de grises (con un solo canal). Imaginemos una unidad en la primera capa de una red neuronal que toma como entrada los valores de píxeles de un pequeño parche rectangular de la imagen, como se muestra en la figura. A este parche se le llama el campo receptivo de la unidad y representa la idea de localidad. Nuestro objetivo es que los pesos asociados a esta unidad aprendan a detectar características útiles de bajo nivel. La salida de esta unidad se obtiene mediante una combinación lineal ponderada de los valores de entrada, seguida de una transformación no lineal mediante una función de activación:

$$z = \text{ReLU}(W^T X + \omega_0)$$

Donde:

X es un vector de valores de píxel para el campo receptivo, y hemos asumido una función de activación ReLU. Como hay un peso asociado a cada píxel de entrada, los pesos forman una pequeña rejilla bidimensional conocida como filtro, a veces también llamado núcleo, que puede visualizarse como una imagen.

Figura 17 Muestra una capa oculta de una red que recibe los píxeles de una zona de 3×3.

Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.

2.3.3.5 Equivarianza de traslación


Cuando consideramos la tarea de detectar caras en imágenes, surge una cuestión importante: si un pequeño parche en una imagen representa un ojo en una ubicación específica, ¿cómo podemos generalizar este conocimiento a todas las posibles ubicaciones de la imagen sin necesidad de ver ejemplos específicos en el conjunto de entrenamiento? Para abordar esto, replicamos los mismos valores de peso de una unidad oculta en múltiples ubicaciones de la imagen. Estas unidades forman un mapa de características en el que comparten los mismos pesos. Si una zona local de la imagen activa una unidad en una ubicación, el mismo conjunto de valores de píxeles en una ubicación diferente activará la misma unidad en el mapa de características. Este proceso, conocido como equivocidad, se logra mediante conexiones escasas y pesos compartidos entre las unidades ocultas. En resumen, esta transformación es un ejemplo de convolución.

$$C(j, k) = \sum_l \sum_m I(j + l, k + m) K(l, m)$$

Donde hemos omitido la función de activación no lineal para mayor claridad. Esto también es un ejemplo de convolución y a veces se expresa como $C = I \times K$. Observe que, en sentido estricto, se denomina correlación cruzada, lo que difiere ligeramente de la definición matemática convencional de convolución, pero aquí seguiremos la práctica común en la literatura sobre aprendizaje automático y nos referiremos a como una convolución.

Se ilustra en la Figura 18 para una imagen de 3×3 y un filtro de 2×2 . Es importante destacar que, cuando se utiliza la normalización por lotes en una red convolucional, se debe utilizar el mismo valor de media y varianza en cada ubicación espacial dentro de un mapa de características al normalizar los estados de las unidades para garantizar que las estadísticas del mapa de características sean independientes de la ubicación.

Figura 18 Imagen 3×3 convolucionada con un filtro 2×2 para obtener un mapa de características 2×2 .



Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.

Como ejemplo de la aplicación de la convolución, consideramos el problema de detectar bordes en imágenes utilizando un filtro convolucional hecho a mano. Intuitivamente, podemos pensar que un borde vertical se produce cuando hay un cambio local significativo en la intensidad entre píxeles a medida que nos movemos horizontalmente por la imagen. Podemos medirlo convolucionando la imagen con un filtro 3×3 de la forma.


-1	0	1
-1	0	1
-1	0	1

Del mismo modo, podemos detectar bordes horizontales con la transposición de este filtro.

-1	-1	-1
0	0	0
1	1	1

En la figura 19 se presentan los resultados de aplicar dos filtros convolucionales a una imagen de muestra. Observa que en la figura central, si un borde vertical representa un aumento de intensidad del píxel, el punto correspondiente en el mapa de características es positivo (indicado por un color claro). Por otro lado, si el borde vertical corresponde a una disminución de la intensidad del píxel, el punto en el mapa de características es negativo (indicado por un color oscuro).

Figura 19 Resultados de la convolución con 2 diferentes filtros que detectan los bordes.




Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.

2.3.3.6 Convoluciones multidimensionales

Hasta ahora, hemos examinado convoluciones aplicadas a imágenes en escala de grises. Sin embargo, en imágenes a color, tenemos tres canales correspondientes a los colores rojo, verde y azul. Para extender las convoluciones a múltiples canales, simplemente aumentamos la dimensionalidad del filtro. Una imagen con $J \times K$ píxeles y C canales se describe mediante un tensor de dimensionalidad $J \times K \times C$. Podemos introducir un filtro descrito por un tensor de $M \times M \times C$, donde cada canal tiene su propio filtro $M \times M$ independiente. Si no hay relleno y el intervalo es 1, obtenemos un mapa de características de tamaño $(J - M + 1) \times (K - M + 1)$, como se ilustra en la figura 20.

Vamos a explorar una ampliación importante de las convoluciones. Hasta ahora, hemos creado un solo mapa de características en el que todos los puntos comparten el mismo conjunto de parámetros aprendibles. Sin embargo, para un filtro de dimensionalidad $M \times$

Figura 20 Filtro multidimensional que toma datos de los canales R,G y B.

Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.


$M \times C$, se requieren $M^2 C$ parámetros de peso, independientemente del tamaño de la imagen. Además, cada unidad tiene un parámetro de sesgo asociado. Este enfoque es similar a tener un solo nodo oculto en una red totalmente conectada, lo que limita su capacidad para detectar solo un tipo de característica. Para construir modelos más flexibles, simplemente incorporamos varios de estos filtros, donde cada filtro tiene su propio conjunto independiente de parámetros, generando su propio mapa de características.

2.3.3.7 Pooling

Las capas convolucionales codifican la equivanianza de traslación. Si un pequeño parche de píxeles cambia de ubicación en la imagen, las salidas correspondientes en el mapa de características también se desplazarán. Esto es útil para tareas como la localización de objetos en una imagen. Sin embargo, en aplicaciones como la clasificación de imágenes, deseamos que la salida sea invariante a las traslaciones de la entrada. En todos los casos, buscamos que la red aprenda una estructura jerárquica en la que las características complejas se construyan a partir de características más simples del nivel anterior. La relación espacial entre estas características más simples es crucial. Por ejemplo, las posiciones relativas de los ojos, la nariz y la boca determinan la presencia de una cara, no solo la existencia de estos rasgos en ubicaciones arbitrarias de la imagen. Aunque los pequeños cambios en las posiciones relativas no afectan la clasificación, queremos ser invariantes a esas pequeñas traslaciones de las características individuales. La agrupación aplicada a la salida de la capa convolucional

logra este objetivo.

Figura 21 Max-pooling de 2×2 píxeles de un mapa de características.



Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.

Existen varias opciones de funciones de agrupación. Por ejemplo, la agrupación media calcula la media de los valores en el campo receptivo correspondiente del mapa de características. Todas estas opciones introducen cierto grado de invariancia local a las traslaciones. Por lo general, aplicamos el pooling de forma independiente a cada canal de un mapa de características.

Después de las capas convolucionales, se aplican capas de pooling para reducir la dimensionalidad espacial, reteniendo la información más relevante. La operación de max-pooling, por ejemplo, selecciona el máximo valor en una ventana de tamaño $p \times p$:

$$\text{MaxPooling}(\mathbf{I})(i,j) = \max_{0 \leq m,n < p} \mathbf{I}(pm + i, pn + j)$$

La normalización por lotes (Batch Normalization) se utiliza para acelerar el entrenamiento y estabilizar el aprendizaje. La normalización a través de un mini-lote $\mathbf{B}$ se define como:

$$\hat{x}^{(k)} = \frac{x^{(k)} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}$$

Donde:

μ_B y σ_B^2 son la media y varianza del mini-lote respectivamente.

ϵ es un pequeño valor para evitar la división por cero.

También podemos aplicar el pooling a varios canales de un mapa de características, lo que

permite a la red aprender invarianzas adicionales además de la simple invariancia a las traslaciones. Por ejemplo, si varios canales de una capa convolucional detectan la misma característica pero con diferentes orientaciones, la agrupación máxima de esos mapas de características será aproximadamente invariante a las rotaciones. Además, el pooling permite que una red convolucional procese imágenes de diferentes tamaños. Aunque la salida y algunas capas intermedias deben tener un tamaño fijo, podemos acomodar entradas de tamaño variable ajustando la longitud de zancada del pooling según el tamaño de la imagen, manteniendo constante el número de salidas agrupadas.

2.3.3.8 Clasificación

Finalmente, las capas completamente conectadas (fully connected layers) se utilizan para realizar la clasificación en base a las características extraídas. La activación de cada neurona en la capa totalmente conectada se calcula como:

$$y_i = \phi \left(\sum_j w_{ij} x_j + b_i \right)$$

donde w_{ij} son los pesos y b_i los sesgos. Aquí, ϕ es una función de activación, como la softmax en la capa de salida para obtener probabilidades:

$$\text{softmax}(\mathbf{z})_i = \frac{e^{z_i}}{\sum_j e^{z_j}}$$


2.3.3.9 Ejemplos de arquitecturas de red

La esencia de un modelo de clasificación de imágenes radica en sus capas convolucionales, las cuales son responsables de extraer características de los datos de la imagen. La salida de estas capas es un vector de características que puede ser utilizado como entrada para el clasificador seleccionado. En muchos modelos de redes neuronales convolucionales, este clasificador es una capa totalmente conectada que se encuentra al final de la red.

(Iffat & Giounona, 2018) menciona que es fundamental destacar que la arquitectura de una red neuronal convolucional para clasificación se basa en capas convolucionales que extraen y aprenden diversas características en cada una de sus capas. La cantidad de capas convolucionales necesarias depende de los datos de entrada y de las características que se

desean clasificar. Además, es posible utilizar diferentes funciones de pérdida para distintas tareas, como se ilustra en la figura 22.

Figura 22 Ejemplos de diferentes arquitecturas de redes convolucionales.




Nota: Adaptado de Hands-On Convolutional Neural Networks with TensorFlow

Uno de los modelos más conocidos y usados es el modelo VGG-19, desarrollado por el Visual Geometry Group, es un ejemplo de arquitectura típica de redes neuronales convolucionales. Consta de 16 capas aprendibles y sigue principios de diseño sencillos. Acepta imágenes de 224×224 píxeles con tres canales de color. Las capas convolucionales utilizan filtros de 3×3 con función de activación ReLU. El muestreo descendente se realiza mediante operaciones de maxpooling con un paso de 2 y un filtro de 2×2 , reduciendo las unidades en un factor de 4. La primera capa aprendible toma un “cubo” de $3 \times 3 \times 3$ de los canales de entrada, compartiendo parámetros entre todas las unidades del mapa de características. Hay 64 canales en la primera capa, generando un tensor de salida de $224 \times 224 \times 64$. La segunda capa también es convolucional y tiene 64 canales. Luego, se aplican más capas convolucionales y maxpooling para obtener mapas de características de tamaños 112×112 . Las capas 3 y 4 también son convolucionales, con una dimensionalidad de 112×112 , y cada una tiene 128 canales. Para compensar la reducción del muestreo en la capa de maxpooling, se aumenta el número de canales en las capas subsiguientes. Esto garantiza que el número de variables en cada capa no disminuya demasiado rápido a lo largo de la red. Después de otro paso de maxpooling para obtener un mapa de características de 56×56 , se aplican tres capas convolucionales adicionales, cada una con 256 canales, duplicando nuevamente la cantidad de canales. Luego, se realiza otro maxpooling para obtener mapas de características

de 28×28 , seguido de tres capas convolucionales más, cada una con 512 canales, y otro maxpooling, reduciendo la muestra a mapas de características de 14×14 . Posteriormente, se aplican tres capas convolucionales adicionales, cada una con 256 canales. Finalmente, hay tres capas totalmente conectadas sin compartir parámetros, lo que significa que son capas de red neuronal estándar con conectividad total.


Figura 23 La arquitectura de una red convolucional típica llamada VGG-19.



Nota: Adaptado de Aprendizaje Profundo Conceptos y Fundamentos.

La capa final de max-pooling en el modelo VGG-16 consta de 512 canales de 7×7 , lo que da un total de 25,088 unidades. La primera capa totalmente conectada tiene 4,096 unidades, cada una conectada a todas las unidades del mapa de características de agrupamiento máximo. Le sigue una segunda capa totalmente conectada con 4,096 unidades, y finalmente, una tercera capa totalmente conectada con 1,000 unidades, lo que permite que la red se aplique a problemas de clasificación con 1,000 clases. Todas las capas de aprendizaje en la red utilizan funciones de activación ReLU, excepto la capa de salida, que utiliza una función de activación softmax. En total, VGG-16 tiene aproximadamente 138 millones de parámetros que se aprenden de forma independiente. La mayoría de estos parámetros (casi 103 millones) se encuentran en la primera capa totalmente conectada, mientras que la mayoría de las conexiones están en la primera capa convolucional.


Figura 24 Arquitectura de VGG19 y filtros de la primera capa convolucional




Nota: Se muestra los diferentes filtros aprendidos en la primera capa de la red neuronal convolucional. obtenido de

https://microscope.openai.com/models/vgg19_caffe?models.technique=deep_dream

La figura muestra la interfaz de usuario de la herramienta Microscope de OpenAI, enfocándose en la primera y segunda capa convolucional del modelo VGG19. La interfaz muestra diversas visualizaciones que reflejan las características que la capa de la red neuronal convolucional ha aprendido a identificar. Cada imagen ilustra la activación de un filtro distinto en respuesta a una entrada, representada por patrones vibrantes y complejos que varían en color y estructura.


Figura 25 Arquitectura de VGG19 y filtros de la segunda capa convolucional

Nota: Se muestra los diferentes filtros aprendidos en la segunda capa de la red neuronal convolucional. obtenido de https://microscope.openai.com/models/vgg19_caffe?models.technique=deep_dream

Figura 26 Arquitectura de VGG19 y filtros de la cuarta capa convolucional

Nota: Se muestra los diferentes filtros aprendidos en la cuarta capa de la red neuronal convolucional. obtenido de https://microscope.openai.com/models/vgg19_caffe?models.technique=deep_dream

La figura 27 muestra la interfaz de una herramienta llamada “CNN EXPLAINER Learn Convolutional Neural Network (CNN)”. Esta interfaz visualiza la arquitectura de una red neuronal convolucional (CNN) con tres canales Azul, verde y rojo. Se pueden ver varias capas, incluyendo capas de entrada, capas convolucionales (conv1, conv1), capas de pooling (pool1) y capas completamente conectadas. Cada capa está representada por pequeñas imágenes en miniatura que muestran mapas de características o filtros aplicados en esa etapa de la red. Estas visualizaciones ayudan a entender cómo las CNNs procesan y transforman los datos de entrada en una salida a través de múltiples etapas de extracción de características y reducción de dimensionalidad.



Nota: Se muestra la convolucion de una imagen de una grieta en sus tres canales Rojo, Verde y azul. obtenido de <https://poloclub.github.io/cnn-explainer/>

ConvNetJS es una demo que entrena una red neuronal convolucional en el conjunto de datos de dígitos MNIST directamente en el navegador, utilizando solo Javascript. El conjunto de datos es bastante sencillo y se puede esperar una precisión de alrededor del 99% en pocos minutos como se muestra en la figura 28. La red toma una imagen MNIST de 28x28 por un canal y recorta una ventana aleatoria de 24x24 con 8 filtros cada kernel utiliza la función de activación relu, seguidamente una capa de Max.pooling para redimensionar la imagen. De manera similar se inicia la segunda capa convolucional con 12x12 con 16 filtros luego se utiliza la función relu y se redimensiona con una capa de Maxpoolin 4x4 por 16 filtros. Luego se repite el proceso hasta terminar en un vector de 1x10x1 y de salida la función Softmax.

Figura 28 Entrenamiento una red neuronal convolucional en un dataset de dígitos

Nota: Se muestra la arquitectura de una red neuronal convolucional de forma interactiva obtenida de <https://cs.stanford.edu/people/karpathy/convnetjs/demo/mnist.html>

Capítulo III

Método de la Investigación

3.1 Enfoque

Esta investigación se llevará a cabo desde un enfoque cuantitativo. Para ello, se recopilarán datos mediante un muestreo representativo, midiendo la variable de fisuras y grietas en estructuras de concreto. Se utilizarán instrumentos y fotografías tomadas en un contexto específico, y se analizarán las imágenes obtenidas para llegar a una serie de conclusiones.

3.2 Alcance

Este estudio se enmarca en un enfoque descriptivo. En él, se detallarán los procedimientos y técnicas utilizados para adquirir, procesar y analizar imágenes de fisuras y grietas en estructuras de concreto de puentes. Además, se abordará la recopilación, evaluación, el entrenamiento y la modelización de redes neuronales artificiales.

3.3 Diseño de investigación

El diseño de este estudio es de carácter no experimental, específicamente de tipo transversal y descriptivo. En otras palabras, no se manipularán las variables, no habrá intervención en los resultados y se realizará una única medición en un momento específico para observar y describir las variables, así como analizar su interrelación.

3.4 Población y muestra

3.4.1 Población

Para la presente investigación la población es considerado 40000 fotografías, con 20000 casos de daños de fisuras y grietas en estructuras de concreto y 20000 casos sin daños de fisuras y grietas en estructuras de concreto. También se ha considerado vídeos y fotografías tomadas con un Dron y recolectadas en los puentes de Huatatas y Chacco de la provincia de Huamanga.

A) Unidad de muestreo

La unidad de muestro son las fisuras y las grietas fotografiadas con un Dron.

B) Unidad de análisis

Las fisuras y grietas de los puentes Huatatas y Chacco.

C) Delimitación de la población

De acuerdo a la presente investigacion nos centramos solo en la grietas y fisuras estructurales de los puentes Huatatas y Chacco de acuerdo a sus particularidades que se quiere investigar.

3.4.2 Muestra

El muestreo es probabilístico por racimos, donde se han identificado 2 estructuras de concreto que muestren el estado de los puentes en la Provincia de Huamanga. La muestra tomada son 28000 imágenes fotografiadas en los puentes de Huatatas y Chacco.

A) Método de selección de la muestra

Para la presente investigación se utilizara en método de selección estadístico o un muestreo probabilístico.

B) Tamaño de muestra

El tamaño de la muestra será la totalidad de la población para obtener mejores resultados en el análisis de las imágenes.

3.5 Hipótesis

3.5.1 Hipótesis general

Un modelo de redes neuronales artificiales para detectar fisuras y grietas usando imágenes digitales tomadas de estructuras de concreto en la Provincia de Huamanga.

3.5.2 Hipótesis específicas

- a) La cantidad de capas y neuronas en el modelo de una red neuronal artificial tiene un efecto positivo y significativo en la precisión de la detección de las fisuras y grietas en una estructura de concreto usando imágenes.
- b) Los pesos sinápticos de un modelo de Redes Neuronales Artificiales optimizados mediante un algoritmo aumentan la precisión y el recall del reconocimiento de fisuras y grietas en estructuras de concreto a partir de imágenes.
- c) Existe una función de activación más óptima que las demás para un modelo de Redes Neuronales Artificiales que determina las fisuras y grietas en estructuras de concreto a partir de imágenes.

3.6 Operacionalización de variables

3.6.1 Variables e indicadores

La variable y los indicadores se muestran en la tabla 2 .

Tabla 2 *Variable e Indicadores.*

Variable	Indicadores	Medición
Modelo de Redes Neuronales Artificiales	Tipo de Red Neuronal	Adimensional
	Cantidad de neuronas	Unidad
	Cantidad de capas	Unidad
	Tipo de función	Adimensional
	Arquitectura neuronal	Adimensional

Adoptada de: Elaboración Propia

3.7 Técnicas e instrumentos

3.7.1 Técnicas

1. Técnica de normalización de datos.
2. Extracción de características.
3. Capas de Agrupamiento (Pooling).
4. Ajuste fino de los parámetros de la red para mejorar el rendimiento.
5. Técnicas de clasificación utilizando capas conectadas al final de la red.

3.7.2 Instrumentos

- Dron equipado con cámara digital y smartphone para captura de imágenes.
- Laptop core i7 con GPU de 6GB para entrenamiento y ejecución del modelo.
- Frameworks como TensorFlow o PyTorch.
- Métricas de evaluación del modelo como precisión, recall, F1-score.
- ACI 224.R-01 (2008) Control Of Cracking In Concrete Structures, American Concrete Institute.
- ACI 224.1R (2007) Causes, Evaluation and Repair of Cracks in Concrete Structures, American Concrete Institute.
- CIP 04-NRMCA (2014) Cracking Concrete Surfaces, National Ready Mixed Concrete Association.

3.8 Técnicas estadísticas para el procesamiento de la información

Para el análisis e interpretación de datos se desarrollará a través de la aplicación de la estadística descriptiva (cuadros y gráficos estadísticos), se utilizará las librerías de Python. Las medidas de tendencia central serán importantes en la interpretación dado que describen a un conjunto de elementos por la forma en que se comporta su centro de distribución. Las medidas de tendencia central (Media, Mediana y Moda) sirven como puntos de referencia para interpretar las calificaciones que se obtiene en una prueba. Las medidas de tendencia central no son suficientes para describir una distribución o conjunto de datos. Por tanto,

una buena descripción de una distribución requiere, además de un valor ‘promedio’ de las observaciones (es decir, una medida de tendencia central), alguna medida de la dispersión o variabilidad de los valores observados. Esta información es proporcionada por indicadores que se conocen como ‘medidas de dispersión’. Los descriptores o indicadores de dispersión o variabilidad más comunes son la desviación estándar y la varianza.

1. Se hace un análisis estadístico.
2. Análisis y limpieza de datos.
3. Procesamiento de datos: Tensorflow.
4. Evaluación de las variables usando librerías Phyton.
5. Elaboración del reporte de precisión de la arquitectura de la neuronal artificial.

3.8.1 Contrastación de Hipótesis por prueba de bondad

Para la contrastación de la hipótesis de datos categóricos utilizaremos estadística inferencial y la prueba de McNemar, para ello plantearemos dos hipótesis:

Hipótesis Nula H_0 .

Hipótesis Alternativa H_1 .

	Desc A1	DescA2
Desc A1	A	B
Desc A2	C	D

Así pues, la fórmula de la prueba de McNemar es la siguiente:

$$\chi_{MN}^2 = \frac{(|B - C| - 1)^2}{B + C}$$

Donde:

χ^2 es el estadístico de la prueba de bondad de ajuste, el cual sigue una distribución chi-cuadrado con $k - 1$ grados de libertad.

k es el tamaño de la muestra de datos.

B y C son los elementos no diagonales de la tabla de contingencia.

De manera análoga, al considerar un nivel de significación α , se compara el estadístico de la prueba calculado con el valor crítico de la prueba para decidir si rechazar la hipótesis nula o

la hipótesis alternativa en el contraste de hipótesis:

Si el estadístico de la prueba es menor que el valor crítico $\chi^2_{1-\alpha|k-1}$, se rechaza la hipótesis alternativa (y se acepta la hipótesis nula).

Si el estadístico de la prueba es mayor que el valor crítico $\chi^2_{1-\alpha|k-1}$, se rechaza la hipótesis nula (y se acepta la hipótesis alternativa).

Si $\chi^2 < \chi^2_{1-\alpha|k-1}$ se rechaza H_1

Si $\chi^2 > \chi^2_{1-\alpha|k-1}$ se rechaza H_0

3.8.2 Prueba de p de chi-cuadrado

La fórmula para el valor (p) en una prueba de chi-cuadrado se relaciona con la discrepancia entre las frecuencias observadas y las frecuencias esperadas bajo la hipótesis nula. Aquí está la expresión matemática:

$$[p = P(\chi^2 \geq \chi^2_{\text{obs}} | H_0)]$$

Donde:

(χ^2) es la estadística de prueba chi-cuadrado.

(χ^2_{obs}) es el valor observado de la estadística chi-cuadrado.

(H_0) representa la hipótesis nula.

3.9 Desarrollo del trabajo de tesis

En el presente estudio, emplearemos redes neuronales convolucionales, conocidas por sus siglas en inglés como CNN. Estas redes utilizan diversas capas o layers, siendo la más relevante y característica la capa convolucional. Dicha capa opera mediante filtros tridimensionales de pequeñas dimensiones, desplazándose sobre la imagen para obtener las salidas correspondientes.

La premisa fundamental es que el filtro se desplaza por la imagen, capturando características relevantes mientras reduce el tamaño de la imagen resultante. Es común aplicar múltiples filtros en cada posición de la imagen (como se muestra en el paso 3 de la figura). La intención es que cada uno de estos filtros extraiga características específicas de la imagen, las cuales serán cruciales para lograr una representación expresiva y completa.

3.9.1 Recopilación de Datos

En la investigación propuesta, se define un conjunto de datos como una recopilación sistemáticamente organizada de información utilizada en el proceso de entrenamiento, validación y evaluación de la arquitectura de la red neuronal convolucional. En el contexto específico de las Redes Neuronales Convolucionales (CNN), estos datos suelen incluir videos e imágenes de fisuras y grietas en estructuras de concreto de diversas infraestructuras ubicadas en la provincia de Huamanga. Posteriormente, la red se encargará de comprender, clasificar e interpretar las fotografías presentadas a la red neuronal convolucional. Este conjunto de datos se divide tradicionalmente en tres subconjuntos: entrenamiento, validación y prueba.

Figura 29 Fotogrametría del puente Huatatas y Chacco.




Nota: Recopilación de datos a través de un dron.

A) Conjunto de Entrenamiento

El conjunto de entrenamiento contiene ejemplos de datos en 2 clases que se utilizan para ajustar los parámetros del modelo durante la fase de entrenamiento. La CNN aprende a reconocer patrones y características relevantes en las imágenes o datos de entrada a medida que se le presenta este conjunto. Cuanto más diverso y representativo sea el conjunto de

entrenamiento, mejor será el rendimiento del modelo. Está constituido por una amplia variedad de ejemplos que instruyen directamente a la red. En el caso de las redes neuronales convolucionales, cada imagen dentro de este conjunto debe estar asociada con la clase correcta o con información relevante que el modelo busca aprender.


Figura 30 Imágenes con fisuras.



Nota: Dataset de estructuras de concreto con fisuras y grietas.

B) Conjunto de Validación

El conjunto de validación se emplea para ajustar los hiperparámetros del modelo y evaluar su capacidad de generalización. A diferencia del conjunto de entrenamiento, que se utiliza para ajustar los pesos del modelo, el conjunto de validación no afecta directamente los parámetros del modelo. En cambio, su función es monitorear el rendimiento del modelo en datos no vistos previamente, lo que ayuda a detectar el sobreajuste y a seleccionar el mejor modelo. Este conjunto desempeña un papel crucial en la prevención del sobreajuste a los datos de entrenamiento.

Figura 31 Imágenes sin fisuras.


Nota: Dataset de estructuras de concreto sin fisuras y grietas.

C) Conjunto de Prueba

El conjunto de prueba comprende datos previamente no observados por el modelo y se utiliza para valorar su rendimiento global y su habilidad para generalizar a nuevas instancias. A diferencia de los conjuntos de entrenamiento y validación, el conjunto de prueba no se utiliza para ajustar los parámetros del modelo. Su objetivo es proporcionar una estimación imparcial del rendimiento del modelo en situaciones del mundo real.

3.9.2 Preparación de los Datos

En el entrenamiento de una red neuronal convolucional (CNN), la preparación de los datos es un paso crucial antes del inicio del aprendizaje efectivo. Esta preparación incluye la limpieza, el etiquetado, y el preprocesamiento de los datos, entre otros pasos. A continuación, se detallan estos procesos:

Figura 32 Recopilación de las fotografías para el entrenamiento de la red neuronal.

Nota: División del dataset en tres sub-conjuntos: Entrenamiento, Validación y Prueba.


A) Limpieza

Este paso implica revisar y preparar el conjunto de datos para asegurar que esté libre de errores, inconsistencias o corrupción. En el contexto del entrenamiento de CNN para tareas de clasificación de imágenes (en nuestra investigación de clasificación entre grietas y no grietas), este paso puede incluir:

- Verificar la integridad de las imágenes: asegurarse de que las imágenes no estén dañadas o corruptas y puedan ser procesadas por la red.
- Remover datos irrelevantes: eliminar imágenes que no pertenecen a ninguna de las categorías de interés (en el ejemplo, imágenes que no son ni perros ni gatos), o que son ambiguas y podrían confundir al modelo.
- Corregir errores en los datos: si se identifican imágenes mal clasificadas en el conjunto inicial, estas deben ser corregidas para evitar el aprendizaje de correlaciones incorrectas.

B) Etiquetado

Es el proceso de asignar una etiqueta o categoría a cada ejemplo en el conjunto de datos. Esta etiqueta es lo que la red intentará predecir durante el entrenamiento y posteriormente en su aplicación. En el entrenamiento de una CNN para clasificación de imágenes, el etiquetado

Figura 33 Ploteando las imágenes sin fisuras.

Nota: Se utilizo GoogleCollab.

implicaría:

- Asignación de categorías: cada imagen debe ser clasificada en las categorías definidas, en este caso, asignando la etiqueta 'grieta' o 'no grieta'. Es crucial que este proceso sea realizado con precisión para garantizar la efectividad del aprendizaje.

C) Preprocesamiento


En el marco de esta investigación, el preprocesamiento de datos se define como el conjunto de técnicas aplicadas para adecuar los datos a un formato óptimo para el entrenamiento de la red neuronal. Este proceso comprende:

- Ajuste del tamaño de las imágenes: Dado que las Convolutional Neural Networks (CNN) requieren que todas las entradas tengan las mismas dimensiones, es necesario redimensionar las imágenes al tamaño esperado por la entrada de la red.
- Normalización de los valores de píxeles: Para optimizar el desempeño de muchas CNN, se lleva a cabo la normalización de los valores de los píxeles, por ejemplo, para obtener un rango de valores entre 0 y 1, o de -1 a 1. Este procedimiento facilita la convergencia durante el entrenamiento.

- **Aumento de datos:** Aunque no se menciona explícitamente, la *augmentación de datos* es una técnica de preprocesamiento común que implica la generación de datos adicionales a partir del conjunto existente mediante la aplicación de transformaciones como rotaciones, traslaciones y cambios de escala. Esta práctica incrementa la diversidad del conjunto de datos y contribuye a evitar el sobreajuste.

Cada uno de estos pasos prepara el conjunto de datos no solo para entrenar la CNN de manera más eficiente, sino también para mejorar su capacidad de generalización ante la presencia de nuevos datos no observados.

Figura 34 Ploteando las imágenes con fisuras.



Nota: Se utilizó GoogleCollab.

3.9.3 Diseño del Modelo de CNN

A) Arquitectura

La arquitectura de una red neuronal convolucional se refiere al diseño estructural de la red. Esto incluye la disposición y la conexión de diferentes capas y neuronas dentro de la red. La arquitectura define cómo la información fluye y se transforma a medida que pasa por la red, desde la entrada hasta la salida. Algunos componentes clave de la arquitectura en una CNN

incluyen:

- Capas convolucionales: donde se aplican filtros convolucionales para extraer características de las imágenes de entrada.
- Capas de pooling (subsampling): usadas para reducir las dimensiones de los datos mientras se preserva la información crucial extraída.
- Capas de activación: introducen no linealidades en el modelo permitiendo que la red aprenda una amplia gama de patrones en los datos.
- Capas completamente conectadas (densas): cada neurona en estas capas está conectada a todas las neuronas en la capa anterior, y suelen ubicarse hacia el final de la red, antes de la capa de salida, para realizar la clasificación basada en las características extraídas.
- Capa de salida: define la salida final de la red, como la clasificación de imágenes en categorías.

La selección de una arquitectura adecuada es un paso crítico en el diseño de una CNN efectiva, ya que dicta la capacidad de la red para aprender de los datos y generalizar a nuevos ejemplos no vistos.

Creando un directorio para el entrenamiento de la red neuronal como se muestra en la siguiente figura 35

Figura 35 Se define un directorio para las imagenes.

```
def generate_df(image_dir, label):
    filepaths = pd.Series(list(image_dir.glob(r'*.jpg')), name='Filepath')
    labels = pd.Series(label, name='Label', index=filepaths.index)
    df = pd.concat([filepaths, labels], axis=1)
    return df
```

```
positive_df = generate_df(positive_dir, label="POSITIVE")
negative_df = generate_df(negative_dir, label="NEGATIVE")

all_df = pd.concat([positive_df, negative_df], axis=0).sample(frac=1.0,
    random_state=1).reset_index(drop=True)
all_df
```

Nota: Se combina las rutas de los archivos y las etiquetas en un DataFrame.

B) Hiperparámetros

Los hiperparámetros son parámetros configurables que gobiernan el proceso de entrenamiento de la red pero que no se actualizan durante el aprendizaje automático de la red. En otras palabras, estos parámetros deben ser definidos por el diseñador del modelo antes del entrenamiento y tienen una influencia significativa en el comportamiento y rendimiento de la red. Algunos ejemplos de hiperparámetros en el contexto de entrenamiento de una CNN incluyen:

- Tasa de aprendizaje: determina cuánto se ajustan los pesos de la red en respuesta al error calculado en cada iteración del entrenamiento.
- Tamaño del lote (batch size): cantidad de ejemplos de entrenamiento utilizados en una iteración del entrenamiento antes de que se actualicen los pesos.
- Número de épocas: cuántas veces se presenta todo el conjunto de datos al modelo durante el entrenamiento.
- Momentum y decay: parámetros que ajustan la tasa de aprendizaje a lo largo del tiempo para mejorar la convergencia.
- El número de filtros en cada capa convolucional, el tamaño de los filtros, y el stride: influyen en cómo la red percibe la información espacial de las entradas. Ajustar los hiperparámetros es un proceso iterativo y a menudo experimental. La selección óptima de hiperparámetros puede mejorar significativamente la capacidad de la red para aprender patrones complejos en los datos, minimizar el sobreajuste y maximizar el rendimiento general del modelo.

3.9.4 Entrenamiento del Modelo

El entrenamiento de un modelo de CNN implica una serie de pasos iterativos que involucran la propagación hacia adelante de las entradas, el cálculo de la pérdida, la retropropagación de los gradientes y la optimización de los pesos para mejorar el rendimiento del modelo en la tarea de determinación de grietas y no grietas.

primeramente tenemos que configurar el entorno de entrenamiento: Seleccionar el hardware (CPU, GPU) y el software (frameworks como TensorFlow, PyTorch) a utilizar.

A) Inicialización de pesos

En el inicio del entrenamiento, los pesos de la red neuronal se inicializan con valores aleatorios pequeños. Esto se hace para romper la simetría y permitir que la red comience a aprender patrones desde cero. La elección de la inicialización de pesos puede influir en la velocidad y la convergencia del entrenamiento, por lo que es importante considerar diferentes estrategias de inicialización.

Figura 36 Construyendo el Modelo de la Red Neuronal Convolutacional.

```
inputs = tf.keras.Input(shape=(120, 120, 3))
x = tf.keras.layers.Conv2D(filters=16, kernel_size=(3, 3), activation
='relu')(inputs)
x = tf.keras.layers.MaxPool2D(pool_size=(2, 2))(x)
x = tf.keras.layers.Conv2D(filters=32, kernel_size=(3, 3), activation
='relu')(x)
x = tf.keras.layers.MaxPool2D(pool_size=(2, 2))(x)
x = tf.keras.layers.GlobalAveragePooling2D()(x)
outputs = tf.keras.layers.Dense(1, activation='sigmoid')(x)

model = tf.keras.Model(inputs=inputs, outputs=outputs)

model.compile(
    optimizer='adam',
    loss='binary_crossentropy',
    metrics=['accuracy']
)

print(model.summary())
```

Nota: Utilizando capas de convolucion, filtros y maxpooling.

B) Propagación hacia adelante (forward propagation)

Durante la propagación hacia adelante, las imágenes de entrada se pasan a través de la red neuronal capa por capa. Cada capa realiza operaciones de convolución, activación y agrupación para extraer características relevantes de las imágenes. Finalmente, se obtiene una salida de la red, que son las predicciones para las clases de interés (en este caso, grietas y no grietas).

C) Cálculo de la función de pérdida

Después de obtener las predicciones de la red, se calcula la función de pérdida para medir cuán diferentes son las predicciones del modelo en comparación con las etiquetas reales

de las imágenes. En el caso de la clasificación de gatos y perros, una función de pérdida comúnmente utilizada es la entropía cruzada categórica, que mide la discrepancia entre las distribuciones de probabilidad predichas y reales.

D) Retropropagación (backpropagation)

Una vez calculada la pérdida, el algoritmo de retropropagación se utiliza para ajustar los pesos de la red y minimizar la pérdida. Este proceso implica calcular las derivadas parciales de la función de pérdida con respecto a cada peso en la red, y luego actualizar los pesos en la dirección que minimice la pérdida. La retropropagación se realiza utilizando el algoritmo de descenso de gradiente, que ajusta los pesos en proporción a la magnitud del gradiente de la función de pérdida.

Figura 37 Entrenamiento del Modelo de la Red Neuronal Convolucional.

```
Epoch 1/100
700/700 [=====] - 208s 296ms/step - loss: 0.5597 - accuracy: 0.7322 - val_loss: 0.1856 - val_accuracy: 0.9525
Epoch 2/100
700/700 [=====] - 140s 200ms/step - loss: 0.1492 - accuracy: 0.9583 - val_loss: 0.1098 - val_accuracy: 0.9691
Epoch 3/100
700/700 [=====] - 138s 197ms/step - loss: 0.0948 - accuracy: 0.9708 - val_loss: 0.1008 - val_accuracy: 0.9663
Epoch 4/100
700/700 [=====] - 139s 198ms/step - loss: 0.0869 - accuracy: 0.9735 - val_loss: 0.0847 - val_accuracy: 0.9786
Epoch 5/100
700/700 [=====] - 142s 203ms/step - loss: 0.0745 - accuracy: 0.9780 - val_loss: 0.0737 - val_accuracy: 0.9748
Epoch 6/100
700/700 [=====] - 144s 205ms/step - loss: 0.0721 - accuracy: 0.9787 - val_loss: 0.0732 - val_accuracy: 0.9800
Epoch 7/100
700/700 [=====] - 143s 204ms/step - loss: 0.0662 - accuracy: 0.9789 - val_loss: 0.0714 - val_accuracy: 0.9743
Epoch 8/100
700/700 [=====] - 146s 208ms/step - loss: 0.0630 - accuracy: 0.9788 - val_loss: 0.0671 - val_accuracy: 0.9775
Epoch 9/100
700/700 [=====] - 146s 209ms/step - loss: 0.0592 - accuracy: 0.9810 - val_loss: 0.0627 - val_accuracy: 0.9809
Epoch 10/100
700/700 [=====] - 143s 204ms/step - loss: 0.0596 - accuracy: 0.9804 - val_loss: 0.0630 - val_accuracy: 0.9827
Epoch 11/100
700/700 [=====] - 142s 203ms/step - loss: 0.0613 - accuracy: 0.9800 - val_loss: 0.0636 - val_accuracy: 0.9823
Epoch 12/100
700/700 [=====] - 140s 200ms/step - loss: 0.0683 - accuracy: 0.9792 - val_loss: 0.0725 - val_accuracy: 0.9832
```

Nota: Entrenamiento del Modelo para 100 épocas.

E) Optimización

Durante el entrenamiento, se utilizan algoritmos de optimización como el descenso de gradiente estocástico (SGD) o Adam para ajustar los pesos de la red de manera eficiente. Estos algoritmos ajustan los pesos en cada iteración del entrenamiento para minimizar la función de pérdida. La elección del algoritmo de optimización y la configuración de sus hiperparámetros pueden afectar significativamente la velocidad y el rendimiento del entrenamiento.

3.9.5 Evaluación del Modelo

Evaluar el modelo utilizando el conjunto de datos de prueba para medir su desempeño general como: precisión, sensibilidad, especificidad, etc. Algunos ejemplos de evaluación del Modelos en el contexto de entrenamiento de una Red neuronal Convolutacional:

A) Precisión (Accuracy)

Es la proporción de predicciones correctas (verdaderos positivos y verdaderos negativos) sobre el total de predicciones realizadas por el modelo. Se calcula como:

$$\frac{TP + TN}{TP + TN + FP + FN}$$

Donde:

TP es el número de verdaderos positivos.

TN es el número de verdaderos negativos.

FP es el número de falsos positivos.

FN es el número de falsos negativos.

B) Recall(Sensibilidad)

Es la proporción de instancias positivas que fueron correctamente identificadas por el modelo.

Se calcula como:

$$\frac{TP}{TP + FN}$$

Donde:

TP es el número de verdaderos positivos.

FN es el número de falsos negativos.

C) F1-score

Es la media armónica de precisión y recall y proporciona un equilibrio entre ambas métricas.

Se calcula como:

$$2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

El modelo de Redes Neuronales Convolucionales presenta un buen desempeño en la tarea de reconocimiento de fisuras y grietas, con una precisión general del 87%. La sensibilidad y la precision también son altas, lo que indica que el modelo es capaz de identificar correctamente tanto fisuras y grietas.

Capítulo IV

Resultados

4.1 Contrastación de la hipótesis

En la presente investigación, utilizaremos datos categóricos y la prueba de bondad, una prueba estadística, para la contrastación de hipótesis. Esta prueba nos permitirá evaluar la distribución de los datos en diferentes categorías, lo que nos ayudará a rechazar o aceptar la hipótesis nula y a obtener conclusiones relevantes para nuestra investigación.

Hipótesis nula (H0)

El modelo de Redes Neuronales Artificiales es capaz de distinguir entre imágenes de fisuras y grietas en estructuras de concreto.

Hipótesis alternativa (H1)

El modelo de Redes Neuronales Artificiales no es capaz de distinguir entre imágenes de fisuras y grietas en estructuras de concreto.

Utilizando la prueba de test de McNemar:

$$\chi_{MN}^2 = \frac{(|B - C| - 1)^2}{B + C}$$

y la prueba p para chi-cuadrado

$$[p = P(\chi^2 \geq \chi_{\text{obs}}^2 | H_0)]$$

Los resultados obtenidos utilizando python se obtiene: Chi-cuadrado del test de McNemar $\chi_{MN}^2 = 1,96$ para la tabla de contingencia de 2x2 de los datos categóricos, para una significancia de 0.05 para la tabla de contingencia de 2x2, para el valor critico para un grado de libertad y el nivel de significancia 0.05 obtenemos $\chi_{\text{critico}}^2 = 3,84$.

Por ende aceptamos la Hipotesis Nula H_0 y descartamos la Hipotesis alternativa H_1 .

Figura 38 Arquitectura de la red neuronal convolucional.

```
Model: "model"
```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 120, 120, 3)]	0
conv2d (Conv2D)	(None, 118, 118, 16)	448
max_pooling2d (MaxPooling2D)	(None, 59, 59, 16)	0
conv2d_1 (Conv2D)	(None, 57, 57, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 28, 28, 32)	0
global_average_pooling2d (GlobalAveragePooling2D)	(None, 32)	0
dense (Dense)	(None, 1)	33

```

Total params: 5,121
Trainable params: 5,121
Non-trainable params: 0

```

Nota: Las diferentes, capas, filtros de la red neuronal convolucional.

Como se puede observar en la figura 40 , el modelo de Redes Neuronales Convolucionales tiene una precisión del 98.36% en el conjunto de prueba, lo que indica que es capaz de clasificar correctamente la mayoría de las imágenes de elementos estructurales que tienen grietas y no tiene grietas. Además, el valor critico para una significancia de que 0.05, lo que significa que podemos rechazar la hipótesis nula y aceptar la hipótesis alternativa de que el modelo se ajusta bien a los datos.

A) Hipótesis general

La arquitectura de la red neuronal convolucional se muestra en el AnexoF, consta de una capa de entrada que recibe imágenes de 120x120 píxeles con 3 canales de color.

Luego, se aplican capas de convolución para detectar características mediante filtros. La primera convolución tiene 16 filtros y la segunda, 32, reduciendo las dimensiones de la imagen.

Seguidamente se utiliza la capa de Maxpoolin2D de agrupaciones máximas para reducir dimensiones y conservar información relevante. En la penúltima capa se utiliza una agrupación global promedio GlobalAveragePooling2D Reduce aún más las dimensiones, preparando los datos para la clasificación. Finalmente, una capa densa produce la salida final y una función de activación sigmoide.

B) Hipótesis específico 1

Se analizó con varias capas convolucionales y kernel, maxpooling y diferentes capas de salida, así como la cantidad de neuronas en cada capa, afecta el rendimiento del modelo para detectar fisuras. En general, se observó que agregar más capas y neuronas mejoraba la precisión, pero llegaba un punto de saturación donde la complejidad adicional no aportaba mejoras significativas. Al aumentar la cantidad de de capas de convolucion solo ralentizaba el entrenamiento, también se utilizo filtros de 5x5, 3x3 y 2x2 y se observo el mejor entrenamiento era como filtros de 3x3. El conjunto de datos SDNET2018, con imágenes de concreto tanto con y sin grietas, fue valioso para entrenar y evaluar diferentes arquitecturas de red.

C) Hipótesis específico 2

Durante el entrenamiento de una red neuronal convolucional, se observó que la red aprende a partir de filtros, patrones que encuentra en las imágenes como se muestra en la figura 27 y no con pesos como una red neuronal multicapa al menos en las capas de convolucion, sin embargo, en la salida se utilizó una sola neurona binaria que conecta las neuronas en el aplanamiento de la matriz de la imagen a vector se observó que se ajustan de acuerdo a la cantidad de épocas de entrenamiento y también varía los filtros respecto a la arquitectura de la red neuronal convolucional, se hizo muchas iteraciones con diferentes arquitecturas y se llegó a un óptimo para reducir el error de clasificación. Se investigó cómo los valores iniciales de estos filtros y su evolución afectan la capacidad del modelo para detectar fisuras y grietas. Inicializar los capas convolucionales correctamente de acuerdo a la calidad y complejidad de la imagen en el input y permitir que la red reconozca patrones que mas adelante utilizara para una buena clasificación y resultó fundamental para un buen rendimiento.

D) Hipótesis específico 3


Las funciones de activación no lineales en las neuronas de la CNN permiten al modelo aprender patrones complejos en las imágenes. Se evaluaron diferentes funciones, como ReLU, sigmoideal y tanh, para determinar cuál era la más adecuada para detectar fisuras. En general, ReLU obtuvo los mejores resultados al permitir un entrenamiento más rápido y evitar problemas de saturación. Además, en la última capa de salida se utilizó la función sigmoide.

4.2 Análisis de resultados

A) Entrenamiento y la validación de un modelo para diferentes épocas

Como se muestran en la figura 39 las diferentes capas de convolucion son fundamentales para monitorear y comprender el desempeño de una red neuronal durante su entrenamiento, permitiendo identificar posibles problemas, ajustar parámetros y garantizar que el modelo esté aprendiendo de manera óptima para realizar predicciones precisas en datos nuevos.

Figura 39 Gráfico de entrenamiento y validación a lo largo del tiempo.



Nota: Entrenamiento y validación para diferentes épocas.

La figura 39 muestra la evolución de la pérdida durante el entrenamiento y la validación de un modelo a lo largo del tiempo.

- Pérdida de Entrenamiento (Azul): Comienza cerca de 0.4 y disminuye rápidamente hasta menos de 0.15 en los primeros dos épocas, luego se estabiliza.
- Pérdida de Validación (Rojo): Inicia por debajo de 0.2 y disminuye rápidamente hasta menos de 0.15, aunque también disminuye, muestra más estabilidad después de cuatro épocas.


Esto indica que el modelo aprende y mejora su precisión durante el entrenamiento, pero la

pérdida de validación no disminuye tan suavemente, lo que podría señalar un sobre ajuste o problemas de generalización del modelo. Es importante monitorear ambas curvas para asegurar que el modelo de la red neuronal convolucional no solo aprenda los datos de entrenamiento, sino que también generalice bien a nuevos datos.

B) Matriz de confusión

Obteniendo la matriz de confusión del entrenamiento y validación del modelo en la figura 40 es una herramienta utilizada en tareas de clasificación para evaluar el rendimiento de un modelo de red neuronal convolucional. Visualmente, muestra el número de predicciones correctas e incorrectas desglosadas por clase en una matriz cuadrada.

Figura 40 Matriz de confusión y precisión del modelo.
 Test Loss: 0.05313
 Test Accuracy: 98.36%



Nota: Matriz de confusión de los diferentes datos de entrenamiento.

Como se muestra en la matriz es útil para evaluar la capacidad de la red neuronal convolucional para clasificar correctamente entre las categorías 'NEGATIVO' y 'POSITIVO'. Un resumen de los elementos obtenidos del entrenamiento son:

- Verdaderos Negativos (TN): 6012 casos correctamente identificados como negativos.

- Falsos Positivos (FP): 57 casos incorrectamente identificados como positivos.
- Falsos Negativos (FN): 140 casos incorrectamente identificados como negativos.
- Verdaderos Positivos (TP): 5791 casos correctamente identificados como positivos.

Después del entrenamiento del modelo de la red neuronal convolucional tiene una precisión del 98.36% y una pérdida de prueba de 0.05313, lo que sugiere que es preciso en sus predicciones.

Como resultado de la investigación, se desarrolló un modelo de red neuronal convolucional utilizando Python (ver anexo A). En el capítulo III, se demostró la considerable cantidad de datos y procesamiento computacional necesarios para entrenar una red neuronal convolucional. Además, se lograron resultados aceptables para la detección de fisuras y grietas en estructuras de concreto, específicamente en puentes de concreto armado ubicados en la provincia de Huamanga.

Conclusiones

Conclusiones

1. Se ha definido un modelo de Redes Neuronales Convolucionales (CNN) para el procesamiento de imágenes de estructuras de concreto. Este modelo es capaz de identificar patrones de fisuras y grietas mediante la extracción de características relevantes de las imágenes, lo que permite una detección precisa y eficiente.
2. La arquitectura del modelo CNN ha demostrado que un mayor número de capas y neuronas puede mejorar la capacidad de aprendizaje del modelo, permitiendo una representación más profunda y detallada de las características de las fisuras y grietas. Sin embargo, también se debe tener en cuenta que un modelo demasiado complejo puede llevar a un sobreajuste, donde el modelo aprende a memorizar las imágenes de entrenamiento en lugar de generalizar a nuevas imágenes.
3. Los pesos sinápticos juegan un papel crucial siempre que exista mas de 3 categorías de clasificación, en nuestra investigación tuvo 2 categorías en la capacidad del modelo para diferenciar entre grietas y no grietas. Un ajuste adecuado de capas convolucionales, a través de técnicas como el descenso de gradiente y la retropropagación, es esencial para optimizar el rendimiento del modelo. La inicialización y la actualización cuidadosa de los pesos pueden conducir a una convergencia más rápida y a una mejor generalización.
4. La elección de la función de activación afecta significativamente la capacidad del modelo para aprender patrones complejos. Funciones como ReLU (Rectified Linear Unit) y Softmax han demostrado ser efectivas en modelos de CNN para tareas de clasificación de imágenes. Estas funciones ayudan a mitigar el problema del gradiente desvanecido y permiten que el modelo aprenda eficientemente.

Por ultimo se concluye en la tesis mencionando que la implementación de un modelo de CNN para la detección de fisuras y grietas en estructuras de concreto muestra un potencial significativo. La arquitectura del modelo, la configuración de las capas y neuronas, la

optimización de los pesos sinápticos y la selección de una función de activación adecuada son factores determinantes para el éxito de la tarea de reconocimiento de patrones en imágenes de concreto. Es importante continuar con la experimentación y validación del modelo con conjuntos de datos más amplios y variados para asegurar su robustez y precisión.

Recomendaciones

1. Se recomienda realizar un balance entre la complejidad del modelo y su capacidad de generalización. Para evitar el sobreajuste, es crucial implementar técnicas como la regularización y el uso de conjuntos de validación durante el entrenamiento. Además, se sugiere ajustar el número de capas y neuronas en función del tamaño y la diversidad del conjunto de datos, permitiendo que el modelo aprenda patrones sin memorizar las imágenes.
2. Es fundamental prestar atención a la inicialización y actualización de los pesos sinápticos. Utilizar técnicas avanzadas como la normalización de lotes (batch normalization) y optimizadores adaptativos (como Adam o RMSprop) puede mejorar la convergencia del modelo y su rendimiento en la clasificación entre grietas y no grietas. Esto es particularmente relevante cuando se trabaja con múltiples categorías, ya que una buena configuración puede facilitar la diferenciación entre clases.
3. Los pesos sinápticos son fundamentales para la precisión del modelo cuando los datos sean estructurados y tengas muchas categorías para clasificar. Durante el entrenamiento, es crucial utilizar técnicas de optimización como el descenso de gradiente para ajustar estos filtros de manera efectiva. Además, la regularización puede ayudar a prevenir el sobreajuste, asegurando que el modelo no solo memorice los patrones de entrenamiento sino que también generalice a nuevos datos.
4. Es recomendable establecer un proceso de evaluación continua del modelo a través de métricas como precisión, recall y F1-score. Esto permitirá identificar áreas de mejora y ajustar los parámetros del modelo según sea necesario. Además, se sugiere realizar pruebas con datos no vistos para asegurar que el modelo mantenga su capacidad de generalización en situaciones reales.

Trabajos futuros

1. Fotografías desde múltiples ángulos mejoran la detección de fisuras y grietas en concreto.
2. Se puede estudiar la integración del modelo con microcomputadoras utilizando el Internet de las cosas(IoT) para mejorar la automatización y eficiencia en la detección de fisuras y grietas.
3. Se puede ampliar la aplicación del modelo a otros tipos de superficies, como muros de albañilería y fachadas.
4. Se puede investigar el uso de técnicas de transferencia de aprendizaje para mejorar la generalización del modelo y reducir el tiempo de entrenamiento.

Referencias bibliográficas

- 224, A. C. (2007). 224.1R-07: Causes, Evaluation, and Repair of Cracks in Concrete Structures. *American concrete Institute*. Retrieved from www.concrete.org
- Ahcene, A. & Ouahabi, A. (2021). Performance assessment of two-dimensional hydraulic models for generation of flood inundation maps in mountain river basins. *ELECTRONICS WORLD*, 10(1), 110–118. Retrieved from [10 . 3390 / electronics10151772](https://doi.org/10.3390/electronics10151772)
- Araya Pizarro, S. (2022). Aportes desde las neurociencias para la comprensión de los procesos de aprendizaje en los contextos educativosl. *Universidad de La Serena*, 1–21. Retrieved from <http://orcid.org/0000-0002-5857-8441>
- Arbaoui, A. & Ouahabi, A. (2021). Concrete Cracks Detection and Monitoring Using Deep Learning-Based Multiresolution Analysis. *Electronics*, 10(15). Retrieved from <https://www.mdpi.com/2079-9292/10/15/1772>
- Arias Campos, K. A. (2022). *Servicio ecosistémico y valoración económica ambiental del centro histórico de Ayacucho, 2021* (Tesis de Maestro). Universidad Nacional de San Cristóbal de Huamanga. Retrieved from <https://repositorio.unsch.edu.pe/handle/UNSCH/4945>
- Banthia, N. & Gupta, R. (2009). Plastic shrinkage cracking in cementitious repairs and overlays. *Materials and Structures/Materiaux et Constructions*, 42(5), 567–579. Retrieved from [10.1617/s11527-008-9403-9](https://doi.org/10.1617/s11527-008-9403-9)
- Bourlard, H. & Kamp, Y. (1988). Auto-Association by Multilayer Perceptrons and Singular Value Decomposition. *Biological cybernetics*, 59, 14–29.
- Broomhead, D. & Lowe, D. (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks. *ROYAL SIGNALS AND RADAR ESTABLISHMENT MALVERN (UNITED KINGDOM), RSRE-MEMO-4148*.
- Calderón Pillaca, O. E. (2016). *Diseño de un modelo metaheurístico para la determinación de caudales de máxima avenida en cuencas urbanas* (Tesis). Universidad Nacional de San Cristóbal de Huamanga. Retrieved from <https://repositorio.unsch.edu.pe/handle/UNSCH/1986>

- Canchari Gutiérrez, E. (2015). Validación de la precipitación GPM (global precipitation Measurement) mediante redes neuronales artificiales de Base Radial. *Universidad Nacional de San Cristóbal de Huamanga*, 1–51. Retrieved from <http://repositorio.unsch.edu.pe/handle/UNSCH/1088>
- Chen, B. & Zhang, X. (2019). Detect concrete cracks based on OTSU algorithm with differential image. *The Journal of Engineering*, (23), 9088–9091. doi:<https://doi.org/10.1049/joe.2018.9191>
- Chen, X. & Du, X. (2021). Semantic Recognition and Location of Cracks by Fusing Cracks Segmentation and Deep Learning. *Complexity*, 2021, 1–15. Retrieved from 10.1155/2021/3159968
- Chung, J. & Gulcehre, C. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *IEEE*, 4, 1–9.
- Day, R. & Clarke, J. (2003). Plastic and thermal cracking. *Advanced Concrete Technology*, 3–17. Retrieved from 10.1016/B978-075065686-3/50249-4
- Elman, J. (1990). Finding structure in time. *Cognitive Science*, 14(21), 65–80.
- Goodfellow, I. (2014). Generative adversarial net. *Advances in Neural Information Processing Systems*, 3.
- Hammer, T. (2006). Early age cracking risk of high-strength lightweight aggregate concrete. *American Concrete Institute, ACI Special Publication, SP-234*(5), 641–660.
- Helene, P. & Pereira, F. (2007). *Manual Rehabilitación Estructuras Hormigón* (2nd ed.). Sao Paulo.
- Hochreiter, S. & Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9(21), 15–30.
- Hsu, S. & Chang, T. (2021). Concrete Surface Crack Segmentation Based on Deep Learning. *Lecture Notes in Civil Engineering*, 128, 1–15. Retrieved from 10.1007/978-3-030-64908-1_3
- Iffat, Z. & Giounona, T. (2018). *Hands-On Convolutional Neural Networks with TensorFlow: Solve computer vision problems with modeling in TensorFlow and Python* (Primera Edición) (P. B. .-. MUMBAI, Ed.). Mumbai. Retrieved from <https://www.packtpub.com/en-us>
- Jaderberg, M. & Simonyan, K. (2016). Spatial Transformer Networks. In *Advances in neural information processing systems Google DeepMind*, 1–15.

- Kaiwen, C. & Xin, X. (2021). Automated crack segmentation in close-range building façade inspection images using deep learning techniques. *Journal of Building Engineering*, 43, 102913. doi:<https://doi.org/10.1016/j.jobe.2021.102913>
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59–69.
- Lecun, Y. & Bottou, L. (1998). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(1), 2278–2324.
- Liu, Y. & Yeoh, J. (2020). Deep Learning-Based Enhancement of Motion Blurred UAV Concrete Crack Images. *Journal of Computing in Civil Engineering*, 34, 11. Retrieved from 10.1061/(ASCE)CP.1943-5487.0000907
- Maguiña Asis, M. & Pascacio Zarzosa, L. (2021). *Desarrollo de una herramienta digital web para la inspección de puentes, mediante la implementación de redes neuronales CNN y visión por computador para la detección de fisuras y vegetación en dos puentes tipo armadura en Ancash, Perú* (Tesis). UNIVERSIDAD PERUANA DE CIENCIAS APLICADAS. Retrieved from <http://hdl.handle.net/10757/668053>
- Meng, M. & Zhu, K. (2021). A Modified Fully Convolutional Network for Crack Damage Identification Compared with Conventional Methods. *Modelling and Simulation in Engineering*, 2021, 1–14. Retrieved from 10.1155/2021/5298882
- Montaño, J. (2002). *Redes neuronales artificiales aplicadas al análisis de datos. Tesis Doc., Palma de Mallorca, España, Universidad de las Islas Baleares.*
- Rosenblat, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 01–23.
- Sasaki, K. & Fujibayashi, M. (2013). Investigation of the cause of reinforcing steel fracture induced by alkali-silica reaction and study on maintenance. *Sustainable Construction Materials and Technologies*, 2013-August(5), 567–579.
- Socha, D. & Ortiz, G. (2005). *Aplicación de redes neuronales MLP a la predicción de un paso en series de tiempo. Fundación Universitaria Konrad Lorenz, Bogotá, pp. 183.*
- Zhang, G. & Patuwo, E. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting* 14, 35–62.

Anexo A

Script del modelo


Código Fuente 1: Modelo de a Red neuronal convolucional

```
1 #Importando librerias para el entrenamiento
2
3 import numpy as np
4 import pandas as pd
5
6 import matplotlib.pyplot as plt
7 import seaborn as sns
8 import plotly.express as px
9
10 from pathlib import Path
11 from sklearn.model_selection import train_test_split
12
13 import tensorflow as tf
14
15 from sklearn.metrics import confusion_matrix, classification_report
16
17 #Recopilando datos para el entrenamiento
18 train_data = train_gen.flow_from_dataframe(
19     train_df,
20     x_col='Filepath',
21     y_col='Label',
22     target_size=(120, 120),
23     color_mode='rgb',
24     class_mode='binary',
25     batch_size=32,
26     shuffle=True,
27     seed=42,
28     subset='training'
29 )
30
31 val_data = train_gen.flow_from_dataframe(
32     train_df,
33     x_col='Filepath',
34     y_col='Label',
35     target_size=(120, 120),
36     color_mode='rgb',
37     class_mode='binary',
38     batch_size=32,
39     shuffle=True,
40     seed=42,
41     subset='validation'
```

```
42 )
43
44 test_data = train_gen.flow_from_dataframe(
45     test_df,
46     x_col='Filepath',
47     y_col='Label',
48     target_size=(120, 120),
49     color_mode='rgb',
50     class_mode='binary',
51     batch_size=32,
52     shuffle=False,
53     seed=42
54 )
55
56 #Entrenamiento de la red neuronal convolucional
57 inputs = tf.keras.Input(shape=(120, 120, 3))
58 x = tf.keras.layers.Conv2D(filters=16, kernel_size=(3, 3), activation='relu')
59 x = tf.keras.layers.MaxPool2D(pool_size=(2, 2))(x)
60 x = tf.keras.layers.Conv2D(filters=32, kernel_size=(3, 3), activation='relu')
61 x = tf.keras.layers.MaxPool2D(pool_size=(2, 2))(x)
62 x = tf.keras.layers.GlobalAveragePooling2D()(x)
63 outputs = tf.keras.layers.Dense(1, activation='sigmoid')(x)
64
65 model = tf.keras.Model(inputs=inputs, outputs=outputs)
66
67 model.compile(
68     optimizer='adam',
69     loss='binary_crossentropy',
70     metrics=['accuracy']
71 )
72
73 print(model.summary())
```

Anexo B

Algoritmo y Pseudocodigo



Nota: Diagrama de flujo de una Red Neuronal Convolutacional.

Algorithm 1: Red neuronal Convolutional

Input: Imagen I de forma (H, W, C)

Capa de Convolucion.

Filtros de Convolucion K

Capa de maxpooling

Capa de aplanamiento.

Output: Predice categoria $\hat{y}$

Initialize Imagen I

1. Input imagen de entrada.

I is already in the form (H, W, C)

2. Capa de Convolucion

for *Cada filtro k en K* **do**

└ $S_k \leftarrow \sum_m \sum_n I(i + m, j + n) * k(m, n)$ Operacion de Convolucion

end for

3. Funcion de activacion(ReLU)

for *cada mapa de características S_k* **do**

└ $A_k \leftarrow \max(0, S_k)$ Activacion ReLu

end for

4. Capa de Pooling(Max Pooling)

for *cada mapa de activacion A_k* **do**

└ $P_k \leftarrow \max_i(A_k)$ Aplincado max pooling

end for

5. Capa de aplanamiento

$F \leftarrow Flatten([P_1, P_2, \dots, P_n])$

6. Capa conectada

$z \leftarrow W \cdot F$

7. Capa de salida (Softmax)

$\hat{y}_i \leftarrow \frac{e^{z_i}}{\sum_j e^{z_j}}$ Activation Softmax

return $\hat{y}$

Algorithm 2: Retropropagación

Input: Vector de entrada x_n
Parámetros de la red w
Función Error $E_n(w)$ para x_n
Función de Activation $h(a)$
Output: Derivadas de la función de error $\frac{\partial E_n}{\partial w_{ji}}$

```
// Propagación hacia adelante
for  $j \in \text{todas las unidades ocultas y de salida}$  do
     $a_j \leftarrow \sum_i w_{ij} z_i + b_j$  //  $z_i$  Incluye inputs  $x_i$ 
     $z_j \leftarrow h(a_j)$  // función de activación
end for
// Evaluación del error
for  $k \in \text{todas las unidades de salida}$  do
     $d_k \leftarrow \frac{\partial E_n}{\partial a_k}$ 
end for
// Propagación hacia atras
Inicializar  $\delta_k$  para todas las unidades de salida
for  $j \in \text{todas las unidades ocultas}$  do
     $\delta_j \leftarrow h'(z_j) \sum_k w_{jk} \delta_k$ 
     $\frac{\partial E_n}{\partial w_{ji}} \leftarrow \delta_j z_i$  // Evalua derivadas
end for
return  $\{\frac{\partial E_n}{\partial w_{ji}}\}$ 
```

Anexo C

Panel fotográfico

Figura C.1 Vista Panorámica.



Nota: Puente de Huatatas.

Figura C.2 Pilar Derecho.



Nota: Union del Pilar derecho y la losa del puente Huatatas.

Figura C.3 Losa y Vereda.

Nota: Baranda y losa del puente Huatatas.

Figura C.4 Pilar Izquierdo.

Nota: Union del Pilar izquierdo y la losa del puente Huatatas.

Figura C.5 Vigas y Diafragma.



Nota: Vigas y Diafragma del puente Huatatas.

Figura C.6 Vista Panorámica.



Nota: Puente Chacco.

Figura C.7 Estribo Izquierdo.

Nota: Union del Pilar y la losa del puente Chacco.

Figura C.8 Estribo Izquierdo.


Nota: Baranda y la losa del puente Chacco.

Figura C.9 Estribo Izquierdo.



Nota: Grieta en el estribo Izquierdo.

Figura C.10 Pilar Central.



Nota: Fisura en el pilar.

Anexo D

Fichas de evaluación de fisuras y grietas en elementos de concreto

Este protocolo es una guía general basada y puede adaptarse a las necesidades específicas del proyecto. Se recomienda consultar con un ingeniero experto en evaluación de estructuras de concreto para obtener un diagnóstico preciso y recomendaciones de reparación.



PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento: CALIDAD-FWEQ-AYAC-02
Revisión: 02
Fecha: 22-10-23

DATOS GENERALES

Ubicación: Puente Huatatas- Ayacucho

N° Registro: 20101/2024

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: ESTRIBO DERECHO

TIPO DE ESTRUCTURA CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE 7.5 m ALTURA 2. m PROFUNDIDAD 15 m SUPERFICIE m2

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.

POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.

POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.

POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.

GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

C

ABERTURA

FISURAS FINAS (<0.2 mm)

FISURAS MEDIAS (0.2 mm - 1 mm)

GRIETAS (>1 mm)

C

PATRON DE LAS FISURAS

FISURAS ALEATORIAS

FISURAS EN FORMA DE MAPA

FISURAS PARALELAS O CONVERGENTES

C

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

C

DETERIORO

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

C

DETERIORO

FISURAS SIN DESPRENDIMIENTO

FISURAS CON DESPRENDIMIENTO DE MATERIAL

FISURAS CON EROSIÓN O CORROSIÓN

C

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma: Frey Espillo

Nombre - Apellido

Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	22-10-23

DATOS GENERALES

Ubicación: **Puente Huatatas- Ayacucho**

N° Registro: **20/01/2024**

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **PILAR**
TIPO DE ESTRUCTURA: **CONCRETO ARMADO**

LOCALIZACION DEL ELEMENTO ESTRUCTURAL: **IZQUIERDO**

DIMENSIONES DEL ELEMENTO:

BASE: **1.0** m ALTURA: **6.0** m PROFUNDIDAD: **15** m SUPERFICIE: m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.
POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.
POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.
POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.
GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

C

ABERTURA

FISURAS FINAS (<0.2 mm)
FISURAS MEDIAS (0.2 mm - 1 mm)
GRIETAS (>1 mm)

C

PATRON DE LAS FISURAS

FISURAS ALEATORIAS
FISURAS EN FORMA DE MAPA
FISURAS PARALELAS O CONVERGENTES

C

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

C

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

DETERIORO

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

C

DETERIORO

FISURAS SIN DESPRENDIMIENTO
FISURAS CON DESPRENDIMIENTO DE MATERIAL
FISURAS CON EROSIÓN O CORROSIÓN

C

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma: **Freud Espillo**
Nombre - Apellido
Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	22-10-23

DATOS GENERALES

Ubicación: Puente Huatatas- Ayacucho

N° Registro: 20/01/2024

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: VIGA
TIPO DE ESTRUCTURA CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL TABLERO

DIMENSIONES DEL ELEMENTO:

BASE 0.8 m ALTURA 1 m PROFUNDIDAD 10 m SUPERFICIE m²

CARACTERISTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.
POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.
POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.
POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.
GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

C

ABERTURA

FISURAS FINAS (<0.2 mm)
FISURAS MEDIAS (0.2 mm - 1 mm)
GRIETAS (>1 mm)

C

PATRON DE LAS FISURAS

FISURAS ALEATORIAS
FISURAS EN FORMA DE MAPA
FISURAS PARALELAS O CONVERGENTES

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.
INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

C

DETERIORO

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

C

DETERIORO

FISURAS SIN DESPRENDIMIENTO
FISURAS CON DESPRENDIMIENTO DE MATERIAL
FISURAS CON EROSIÓN O CORROSIÓN

C

OTROS ASPECTOS

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma: Freddy Espillo
Nombre - Apellido
Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS :DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA,2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	22-10-23

DATOS GENERALES

Ubicación: **Puente Huatatas- Ayacucho**

N° Registro: **20/01/2024**

UBICACIÓN DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **LOSA**

TIPO DE ESTRUCTURA

CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE

5-8

m

ALTURA

0.25

m

PROFUNDIDAD

10

m

SUPERFICIE

m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.

C

POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.

POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.

POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.

GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

ABERTURA

FISURAS FINAS (<0.2 mm)

C

FISURAS MEDIAS (0.2 mm - 1 mm)

GRIETAS (>1 mm)

PATRON DE LAS FISURAS

FISURAS ALEATORIAS

FISURAS EN FORMA DE MAPA

FISURAS PARALELAS O CONVERGENTES

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

C

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

DETERIORO

PRESENCIA DE HUMEDAD

C

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

OTROS ASPECTOS

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

DETERIORO

FISURAS SIN DESPRENDIMIENTO

C

FISURAS CON DESPRENDIMIENTO DE MATERIAL

FISURAS CON EROSIÓN O CORROSIÓN

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma:

Nombre - Apellido

Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	22-10-23

DATOS GENERALES

Ubicación: Puente Huatatas- Ayacucho

N° Registro: 20/01/2024

UBICACIÓN DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: BARANDA
TIPO DE ESTRUCTURA CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL TABLERO

DIMENSIONES DEL ELEMENTO:

BASE 0.15 m

ALTURA 0.15 m

PROFUNDIDAD 2.5 m

SUPERFICIE m²

CARACTERISTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.
POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.
POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.
POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.
GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

C

ABERTURA

FISURAS FINAS (<0.2 mm)
FISURAS MEDIAS (0.2 mm - 1 mm)
GRIETAS (>1 mm)

C

PATRON DE LAS FISURAS

FISURAS ALEATORIAS
FISURAS EN FORMA DE MAPA
FISURAS PARALELAS O CONVERGENTES

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

C

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

DETERIORO

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

C

DETERIORO

FISURAS SIN DESPRENDIMIENTO
FISURAS CON DESPRENDIMIENTO DE MATERIAL
FISURAS CON EROSIÓN O CORROSIÓN

C

OTROS ASPECTOS

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma:

Fred Espilko

Nombre - Apellido

Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento: CALIDAD-FWEQ-AYAC-02
Revisión: 02
Fecha: 24-11-23

DATOS GENERALES

Ubicación: **Puente Chacco- Ayacucho**

N° Registro: **22/01/2024**

UBICACIÓN DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **ESTRIBO IZQUIERDO**

TIPO DE ESTRUCTURA

CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE

11

m

ALTURA

2

m

PROFUNDIDAD

12

m

SUPERFICIE

m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.

POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.

POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.

POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.

GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

C

ABERTURA

FISURAS FINAS (<0.2 mm)

FISURAS MEDIAS (0.2 mm - 1 mm)

GRIETAS (>1 mm)

C

PATRON DE LAS FISURAS

FISURAS ALEATORIAS

FISURAS EN FORMA DE MAPA

FISURAS PARALELAS O CONVERGENTES

C

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

C

DETERIORO

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

C

OTROS ASPECTOS

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

DETERIORO

FISURAS SIN DESPRENDIMIENTO

FISURAS CON DESPRENDIMIENTO DE MATERIAL

FISURAS CON EROSIÓN O CORROSIÓN

C

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma:

Fredd Espillo

Nombre - Apellido

Fecha :

se encontro una grieta de 2 cm en el estribo izquierdo.





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	24-11-23

DATOS GENERALES

Ubicación: **Puente Chacco- Ayacucho**

N° Registro: **22/01/2024**

UBICACIÓN DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **PILAR CONCRETO ARMADO**

TIPO DE ESTRUCTURA

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE **1.3** m ALTURA **8** m PROFUNDIDAD **15** m SUPERFICIE m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.
POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.
POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.
POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.
GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

☐
☐
☐
☒
☐

ABERTURA

FISURAS FINAS (<0.2 mm)
FISURAS MEDIAS (0.2 mm - 1 mm)
GRIETAS (>1 mm)

☒
☐
☐

PATRON DE LAS FISURAS

FISURAS ALEATORIAS
FISURAS EN FORMA DE MAPA
FISURAS PARALELAS O CONVERGENTES

☐
☐
☐

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

☒
☐

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

DETERIORO

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☒
☐

DETERIORO

FISURAS SIN DESPRENDIMIENTO
FISURAS CON DESPRENDIMIENTO DE MATERIAL
FISURAS CON EROSIÓN O CORROSIÓN

☒
☐
☐

OTROS ASPECTOS

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☐
☐

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma: **Frederic Espillio**
Nombre - Apellido
Fecha:

Se encuentra fisuras en ambos caros del pilar de concreto armado





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	24-11-23

DATOS GENERALES

Ubicación: **Puente Chacco- Ayacucho**

N° Registro: **22101/2024**

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **VIGA**

TIPO DE ESTRUCTURA

CONCRETO ARMADO

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE

0.6 m

ALTURA

1.7 m

PROFUNDIDAD

20 m

SUPERFICIE

m²

CARACTERISTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.

POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.

POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.

POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.

GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

☐
☒
☐
☐
☐

ABERTURA

FISURAS FINAS (<0.2 mm)

FISURAS MEDIAS (0.2 mm - 1 mm)

GRIETAS (>1 mm)

☒
☐
☐

PATRON DE LAS FISURAS

FISURAS ALEATORIAS

FISURAS EN FORMA DE MAPA

FISURAS PARALELAS O CONVERGENTES

☒
☐
☐

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

☒
☐

DETERIORO

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☒
☐

DETERIORO

FISURAS SIN DESPRENDIMIENTO

FISURAS CON DESPRENDIMIENTO DE MATERIAL

FISURAS CON EROSIÓN O CORROSIÓN

☒
☐
☐

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☐
☐

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma:

Freddy Espilco

Nombre - Apellido

Fecha:

se encontraron pequeñas fisuras.





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	24-11-23

DATOS GENERALES

Ubicación: **Puente Chacco- Ayacucho**

N° Registro: **22/01/2024**

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **LOSA**

TIPO DE ESTRUCTURA: **CONCRETO ARMADO**

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE **9.9** m ALTURA **0.25** m PROFUNDIDAD **20** m SUPERFICIE m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.

POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.

POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.

POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.

GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

☐
☒
☐
☐
☐

ABERTURA

FISURAS FINAS (<0.2 mm)

FISURAS MEDIAS (0.2 mm - 1 mm)

GRIETAS (>1 mm)

☒
☐
☐

PATRON DE LAS FISURAS

FISURAS ALEATORIAS

FISURAS EN FORMA DE MAPA

FISURAS PARALELAS O CONVERGENTES

☒
☐
☐

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

☒
☐

DETERIORO

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☒
☐
☐
☐

DETERIORO

FISURAS SIN DESPRENDIMIENTO

FISURAS CON DESPRENDIMIENTO DE MATERIAL

FISURAS CON EROSIÓN O CORROSIÓN

☒
☐
☐

PRESENCIA DE HUMEDAD

CORROSION DE ARMADURAS

DEFORMACIONES.

EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☐
☐

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma:

Fred Espillo

Nombre - Apellido

Fecha:





PROTOCOLO DE EVALUACION E IDENTIFICACION DE FISURAS Y GRIETAS EN CONCRETO

TESIS : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024

ID de Documento:	CALIDAD-FWEQ-AYAC-02
Revisión:	02
Fecha:	24-11-23

DATOS GENERALES

Ubicación: **Puente Chacco- Ayacucho**

N° Registro: **22/01/2024**

UBICACION DEL ELEMENTO ESTRUCTURAL

NOMBRE DE ELEMENTO CONSTRUCTIVO: **BARANDA**
TIPO DE ESTRUCTURA: **CONCRETO ARMADO**

LOCALIZACION DEL ELEMENTO ESTRUCTURAL

DIMENSIONES DEL ELEMENTO:

BASE **0.15** m ALTURA **0.2** m PROFUNDIDAD **2.5** m SUPERFICIE m²

CARACTERÍSTICAS DE LAS FISURAS Y GRIETAS

TIPOS DE FISURAS Y GRIETAS

POR RETRACCIÓN: FINAS, RAMIFICADAS, SUPERFICIALES.
POR FLEXIÓN: GENERALMENTE EN ZONAS DE ALTA TENSIÓN.
POR CORTE: DIAGONALES, EN ZONAS DE ESFUERZO CORTANTE.
POR ASENTAMIENTO: EN ZONAS CON HUNDIMIENTO DEL TERRENO.
GRIETAS: FISURAS DE MAYOR TAMAÑO Y PROFUNDIDAD

☐
☐
☐
☐
☒

ABERTURA

FISURAS FINAS (<0.2 mm)
FISURAS MEDIAS (0.2 mm - 1 mm)
GRIETAS (>1 mm)

☐
☐
☒

PATRON DE LAS FISURAS

FISURAS ALEATORIAS
FISURAS EN FORMA DE MAPA
FISURAS PARALELAS O CONVERGENTES

☒
☐
☐

ESTADO DE LAS FISURAS Y GRIETAS

ACTIVIDAD

ACTIVAS: CON MOVIMIENTO RECIENTE, INDICADAS POR POLVO, ÓXIDO, O EXUDACIONES.

☒
☐

INACTIVAS: SIN MOVIMIENTO RECIENTE, SELLADAS O CON MATERIAL DE RELLENO.

DETERIORO

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☒
☐

DETERIORO

FISURAS SIN DESPRENDIMIENTO
FISURAS CON DESPRENDIMIENTO DE MATERIAL
FISURAS CON EROSIÓN O CORROSIÓN

☒
☐
☐

PRESENCIA DE HUMEDAD
CORROSION DE ARMADURAS
DEFORMACIONES.
EVIDENCIA DE TRABAJOS PREVIOS DE REPARACION

☐
☐
☐
☐

LEYENDA

C: CONFORME

NC: NO CONFORME

NA: NO APLICA

APROBACION:

INGENIERO CALIDAD

OBSERVACIONES Y/O COMENTARIO:

Firma: **Freud Espilko**
Nombre - Apellido
Fecha:

se encontro una grieta en la baranda de 3-4 cm de ancho



Anexo E

Guia de uso del Script

E.1 Importación de librerías

Importa las librerías necesarias de TensorFlow y otras librerías que se necesiten para el procesamiento de imágenes.

Figura E.11 Librerías como numpy y pandas.

```
import numpy as np
import pandas as pd

import matplotlib.pyplot as plt
import seaborn as sns
import plotly.express as px

from pathlib import Path
from sklearn.model_selection import train_test_split

import tensorflow as tf

from sklearn.metrics import confusion_matrix, classification_report
```

E.2 Cargar el Dataset

Figura E.12 Creando directorios.

```
positive_dir = Path('../input/surface-crack-detection/Positive')
negative_dir = Path('../input/surface-crack-detection/Negative')
```

E.3 Etiquetar los Dataset

Define el directorio y etiqueta la imagen.

Figura E.13 Etiquetando imagen del directorio.

```
def generate_df(image_dir, label):
    filepaths = pd.Series(list(image_dir.glob(r'*.jpg')), name='Filepath').astype(str)
    labels = pd.Series(label, name='Label', index=filepaths.index)
    df = pd.concat([filepaths, labels], axis=1)
    return df
```

```
positive_df = generate_df(positive_dir, label="POSITIVE")
negative_df = generate_df(negative_dir, label="NEGATIVE")

all_df = pd.concat([positive_df, negative_df], axis=0).sample(frac=1.0, random_state=1).reset_index(drop=True)
all_df
```

E.4 Creando carpeta de salida

Figura E.14 Creando las carpetas de salida.

```
def generate_df(image_dir, label):
    filepaths = pd.Series(list(image_dir.glob(r'*.jpg')), name='Filepath').astype(str)
    labels = pd.Series(label, name='Label', index=filepaths.index)
    df = pd.concat([filepaths, labels], axis=1)
    return df
```

```
positive_df = generate_df(positive_dir, label="POSITIVE")
negative_df = generate_df(negative_dir, label="NEGATIVE")

all_df = pd.concat([positive_df, negative_df], axis=0).sample(frac=1.0, random_state=1).reset_index(drop=True)
all_df
```


Anexo F

Arquitectura de la red neuronal Convolutiva

- Capa de entrada:
 - Tamaño de la imagen: 120×120 Píxeles
 - Canales de entrada: 3 (RGB)
- Primera capa convolutiva (conv2d):
 - Filtros: 16
 - Tamaño del kernel: 3×3
 - Función de activación: ReLU
 - Salida: 118×118 Píxeles
- Primera capa Pooling:
 - Tamaño del Pool: 2×2
 - Salida: 59×59 Píxeles
- Segunda capa convolutiva (conv2d_1):
 - Filtros: 32
 - Tamaño del kernel: 3×3
 - Función de activación: ReLU
 - Salida: 57×57 Píxeles
- Segunda capa Pooling:
 - Tamaño del Pool: 2×2
 - Salida: 28×28 Píxeles
- Capa de Pooling Global:
 - Salida: 32×1
- Capa densa final (dense):
 - Neuronas de salida: 1
 - Función de activación: Sigmoid

La red neuronal convolucional (CNN) diseñada para clasificación binaria de imágenes de 120x120 píxeles con 3 canales de color. La red comienza con una capa de entrada, seguida por dos bloques de convolución y max pooling que extraen y reducen características. La primera capa convolucional utiliza 16 filtros, mientras que la segunda usa 32, ambas con kernels 3x3. Después de los bloques convolucionales, una capa de Global Average Pooling reduce drásticamente el número de parámetros. La red culmina con una capa densa de una sola neurona, típica para clasificación binaria.

Figura F.15 Arquitectura de la red neuronal convolucional.



Anexo G

Matriz de operacionalidad

Determinación de fisuras y grietas en estructuras de concreto mediante el procesamiento de imágenes utilizando un modelo de redes neuronales artificiales en la provincia de Huamanga, 2024

Autor: Freud Watson Espillo Quintanilla

PROBLEMA	OBJETIVO	HIPOTESIS	Metodologia	VARIABLE	DIMENSION	INDICADORES	TECNICAS	INSTRUMENTOS	ESCALAS DE MEDICION
¿Que modelo de Redes Neuronales Artificiales puede determinar fisuras y grietas, mediante procesamiento digital de imágenes tomadas en estructuras de concreto en la Provincia de Huamanga?	Definir un modelo de Redes Neuronales Artificiales para determinar fisuras y grietas, mediante el procesamiento digital de imágenes obtenidos de las estructuras de concreto en la Provincia de Huamanga	Un modelo de redes neuronales para detectar fisuras y grietas usando imágenes digitales tomadas de estructuras de concreto en la Provincia de Huamanga.	<u>Tipo de Investigación:</u> investigación aplicada (genera beneficio y bienestar a la sociedad). <u>Enfoque:</u> Cuantitativo (Ya que esta se basa en la toma de los datos se medirá la variable mediante instrumentos). <u>Alcance (o nivel):</u> Descriptivo (Se describira de los métodos y las técnicas que se empleen para obtener, procesar y analizar las imágenes de fisuras y grietas de estructuras de concreto, así como para evaluar, entrenar y modelar las redes neuronales artificiales). <u>Diseño de Investigación:</u> No experimental, cuantitativa. transversal, porque se realiza una sola medición sobre unidades de estudio, son mediciones que se tomarán en un único tiempo.	<u>Independiente:</u> Modelo de Redes Neuronales Artificiales	Modelo computacional , neuronas artificiales.	Bias y Precisión. Cantidad de neuronas Cantidad de capas Tipo de funcion. Arquitectura neuronal.	Modelacion y simulacion de la red neuronal.	TensorFlow, Pytorch, Keras y GoogleCollab.	De Razon.
Problemas Especificos:	Objetivos Especificos:	Hipotesis Especificas:							
¿Cómo influye la cantidad de capas y neuronas en el aprendizaje del modelo de una red neuronal artificial que detecta las fisuras y grietas en una estructura de concreto usando imágenes?	Analizar la influencia de la cantidad de capas y neuronas en el aprendizaje del modelo de una red neuronal artificial que detecta las fisuras y grietas en una estructura de concreto usando imágenes.	La cantidad de capas y neuronas en el modelo de una red neuronal artificial tiene un efecto positivo y significativo en la precisión de la detección de las fisuras y grietas en una estructura de concreto usando imágenes.		Cantidad de capas y neuronas	Capas de entrada. Capas de Salida. Cantidad de Neurona ocultas.	Error cuadrático medio.La curva ROC.	Técnica del descenso de gradiente.	Python, R y MATLAB.	De Razon.
¿Cómo los pesos sinápticos de un modelo de Redes Neuronales Artificiales pueden mejorar el reconocimiento de fisuras y grietas en estructuras de concreto a partir de imágenes?	Evaluar el efecto de los pesos sinápticos de un modelo de Redes Neuronales Artificiales en el reconocimiento de fisuras y grietas en estructuras de concreto a partir de imágenes	Los pesos sinápticos de un modelo de Redes Neuronales Artificiales optimizados mediante un algoritmo aumentan la precisión y el recall del reconocimiento de fisuras y grietas en estructuras de concreto a partir de imágenes.	<u>Población y muestra:</u> El muestreo es probabilístico por racimos, donde se han identificado 2 estructuras de concreto que muestren el estado de los puentes en la Provincia de Huamanga. <u>Temática y unidad de análisis:</u> La unidad de análisis son la evaluación de fisuras y grietas en estructuras de concreto y la temática u objeto es el procesamiento de imágenes utilizando Redes Neuronales Artificiales. <u>Delimitación espacial y temporal:</u> Grietas y fisuras de estructuras de concreto, año 2024.	Pesos sinápticos	Tipo de Conexión	Coefficiente de determinación. Criterio de información bayesiano	Técnicas de estimación y actualización.	Python, R y MATLAB.	De intervalo
¿Es posible identificar la función de activación mas optima de un modelo de Redes Neuronales Artificiales para determinar las fisuras y grietas en estructuras de concreto a partir de imágenes?	Identificar la función de activación más optima de un modelo de Redes Neuronales Artificiales para determinar las fisuras y grietas en estructuras de concreto a partir de imágenes.	Existe una función de activación más óptima que las demás para un modelo de Redes Neuronales Artificiales que determina las fisuras y grietas en estructuras de concreto a partir de imágenes.		La función de activación	Binaria. Continua Discreta.	La simetría.La no linealidad. La estocasticidad,	Técnicas de comparación.	Python, R y MATLAB.	Nominal



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL

ACTA DE SUSTENTACIÓN DE TESIS N° 064-2024-FIMGC

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERA CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal N° 616-2024-FIMGC-D**, a los veinte días del mes de setiembre de 2024, siendo las 10:00 a.m. reunidos en el Auditorio de la Escuela Profesional de Ingeniería Civil, bajo la presidencia del MSc. Ing. José Ernesto ESTRADA CÁRDENAS y los miembros; MSc. Ing. Edmundo CANCHARI GUTIERREZ, MSc. Ing. Alex Sander IRCAÑAUPA HUAMANÍ, y MSc. Ing. Hemerson LIZARBE ALARCÓN, actuando como secretario docente el MSc. Ing. Kelvis BERROCAL ARGUMEDO, para proceder a la sustentación de tesis para optar el Título Profesional de Ingeniero Civil, del bachiller en Ciencias de la Ingeniería Civil:

Freud Watson ESPILLCO QUINTANILLA

Quien presentó la tesis denominada:

Determinación de fisuras y grietas en estructuras de concreto mediante el procesamiento de imágenes utilizando un modelo de redes neuronales artificiales en la provincia de Huamanga, 2024

Los señores miembros del jurado luego de expuesto la tesis y absueltas las preguntas, delibera y lo declaran:

APROBADO CON NOTA DIECISEIS (16)

Siendo las 12:45 p.m. del día 20 de setiembre de 2024, culmina el acto de sustentación de tesis, y en conformidad a lo actuado los miembros del jurado firmamos al pie del presente.

MSc. Ing. José Ernesto ESTRADA CÁRDENAS
Presidente

MSc. Ing. Edmundo CANCHARI GUTIERREZ
Miembro

MSc. Ing. Alex Sander IRCAÑAUPA HUAMANÍ
Miembro

MSc. Ing. Hemerson LIZARBE ALARCÓN
Miembro

MSc. Ing. Kelvis BERROCAL ARGUMEDO
Secretario docente de la FIMGC

cc:
Archivo



UNSH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL



"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 119-2024-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuela Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 476-2023-FIMGC-UNSH-D**, deja constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : FREUD WATSON ESPILLCO QUINTANILLA
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : DETERMINACIÓN DE FISURAS Y GRIETAS EN ESTRUCTURAS DE CONCRETO MEDIANTE EL PROCESAMIENTO DE IMÁGENES UTILIZANDO UN MODELO DE REDES NEURONALES ARTIFICIALES EN LA PROVINCIA DE HUAMANGA, 2024
Evaluación de la Originalidad : 27 % Índice de Similitud
Identificador de la entrega : 2487176054

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

En señal de conformidad y verificación se firma la presente constancia

Ayacucho, 16 de octubre del 2024


Facultad de Ingeniería de Minas, Geología y Civil

Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

Con depósito para Sustentación y Tramites
Cc. Archivo.

Determinación de fisuras y grietas en estructuras de concreto mediante el procesamiento de imágenes utilizando un modelo de redes neuronales artificiales en la provincia de Huamanga, 2024

por Freud Watson ESPILLCO QUINTANILLA

Fecha de entrega: 16-oct-2024 10:34a.m. (UTC-0500)

Identificador de la entrega: 2487176054

Nombre del archivo: TESIS_FREUD_WATSON_ESPILLCO_QUINTANILLA.pdf (64.29M)

Total de palabras: 22556

Total de caracteres: 127096

Determinación de fisuras y grietas en estructuras de concreto mediante el procesamiento de imágenes utilizando un modelo de redes neuronales artificiales en la provincia de Huamanga, 2024

INFORME DE ORIGINALIDAD

27%

INDICE DE SIMILITUD

15%

FUENTES DE INTERNET

5%

PUBLICACIONES

23%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

Submitted to Universidad Nacional de San
Cristóbal de Huamanga

Trabajo del estudiante

19%

2

hdl.handle.net

Fuente de Internet

1%

3

repository.uaeh.edu.mx

Fuente de Internet

1%

4

Submitted to Universidad Politécnica de
Madrid

Trabajo del estudiante

1%

5

Submitted to uni

Trabajo del estudiante

1%

6

pdfcoffee.com

Fuente de Internet

1%

7

reunir.unir.net

Fuente de Internet

<1%

8	www.virtualpro.co Fuente de Internet	<1 %
9	www.probabilidadyestadistica.net Fuente de Internet	<1 %
10	Submitted to Unviersidad de Granada Trabajo del estudiante	<1 %
11	repositorio.unsa.edu.pe Fuente de Internet	<1 %
12	Submitted to Infile Trabajo del estudiante	<1 %
13	www.consultcreto.com Fuente de Internet	<1 %
14	www.scatec.es Fuente de Internet	<1 %
15	grietaspared.com Fuente de Internet	<1 %
16	repositorio.lamolina.edu.pe Fuente de Internet	<1 %
17	repositorio.utc.edu.ec Fuente de Internet	<1 %
18	www.estudiorodrigo.com Fuente de Internet	<1 %
19	Submitted to Universidad Internacional de la Rioja	<1 %

20

www.repositorio.usac.edu.gt

Fuente de Internet

<1 %

21

sedici.unlp.edu.ar

Fuente de Internet

<1 %

22

www.sap.com

Fuente de Internet

<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo