

Alvarado Huaman Osmer Campos Guerrero Emerso...

ESTIMACIÓN DE DAÑOS EN EL PUENTE TAMBORAPA APLICANDO REDES NEURONALES CONVOLUCIONALES, JAÉ...

- Prueba 1
- Proyectos
- Universidad Nacional de Jaen

Detalles del documento

Identificador de la entrega

trn:oid:::1:3511554748

186 páginas

Fecha de entrega

19 mar 2026, 12:12 p.m. GMT-5

30.103 palabras

Fecha de descarga

19 mar 2026, 12:17 p.m. GMT-5

179.638 caracteres

Nombre del archivo

ESTIMACIÓN_DE_DAÑOS_EN_EL_PUENTE_TAMBORAPA_APLICANDO_REDES_NEURONALES_CONV...pdf

Tamaño del archivo

18.7 MB

 UNIVERSIDAD NACIONAL DE JAÉN

Dr. Christiaan Zayda Apaza Pasca
RESPONSABLE DE LA UNIDAD DE INVESTIGACIÓN
DE LA FACULTAD DE INGENIERÍA




4% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Coincidencias menores (menos de 15 palabras)

Fuentes principales

- 4%  Fuentes de Internet
- 0%  Publicaciones
- 2%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

 UNIVERSIDAD NACIONAL DE JAÉN


Dr. Christian Zayed Apaza Panca
RESPONSABLE DE LA UNIDAD DE INVESTIGACIÓN
DE LA FACULTAD DE INGENIERÍA

Alvarado Huaman Osmer Campos Guerrero Emerso...

ESTIMACIÓN DE DAÑOS EN EL PUENTE TAMBORAPA APLICANDO REDES NEURONALES CONVOLUCIONALES, JAÉ...

 Prueba 1

 Proyectos

 Universidad Nacional de Jaen

Detalles del documento

Identificador de la entrega

trn:oid:::1:3511554748

Fecha de entrega

19 mar 2026, 12:12 p.m. GMT-5

Fecha de descarga

19 mar 2026, 12:17 p.m. GMT-5

Nombre del archivo

ESTIMACIÓN_DE_DAÑOS_EN_EL_PUENTE_TAMBORAPA_APLICANDO_REDES_NEURONALES_CONVO....pdf

Tamaño del archivo

18.7 MB

186 páginas

30.103 palabras

179.638 caracteres




4% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Coincidencias menores (menos de 15 palabras)

Fuentes principales

- 4%  Fuentes de Internet
- 0%  Publicaciones
- 2%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Fuentes principales

- 4% Fuentes de Internet
- 0% Publicaciones
- 2% Trabajos entregados (trabajos del estudiante)

Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1	Internet	repositorio.unj.edu.pe	2%
2	Trabajos del estudiante	Higher Education Commission Pakistan	<1%
3	Internet	revista.estudioidea.org	<1%
4	Internet	la.mathworks.com	<1%
5	Trabajos del estudiante	Universidad Tecnológica Centroamericana UNITEC	<1%
6	Trabajos del estudiante	UNIBA	<1%
7	Internet	www.researchgate.net	<1%
8	Internet	riaa.uaem.mx:8080	<1%
9	Trabajos del estudiante	Universidad Nacional de San Cristóbal de Huamanga	<1%
10	Internet	link.springer.com	<1%
11	Trabajos del estudiante	Mondragon Unibertsitatea	<1%

12	Publicación	Hodes, Scott Gudger. "Adversarial Machine Learning Across the Digital-Physical D...	<1%
13	Trabajos del estudiante	Universidad Internacional del Ecuador	<1%
14	Trabajos del estudiante	Universidad Tecnologica del Peru	<1%
15	Internet	revistas.ucv.edu.pe	<1%
16	Trabajos del estudiante	Pontificia Universidad Catolica del Peru	<1%
17	Trabajos del estudiante	Universidad de Xalapa A. C.	<1%
18	Internet	ibmc.umh.es	<1%
19	Trabajos del estudiante	Universitat Oberta de Catalunya	<1%
20	Trabajos del estudiante	Universidad Anahuac México Sur	<1%
21	Internet	repositorio.puce.edu.ec	<1%
22	Internet	repositorio.umariana.edu.co	<1%
23	Internet	www.techscience.com	<1%

UNIVERSIDAD NACIONAL DE JAÉN
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



ESTIMACIÓN DE DAÑOS EN EL PUENTE TAMBORAPA
APLICANDO REDES NEURONALES CONVOLUCIONALES,
JAÉN - CAJAMARCA - 2025

INFORME FINAL DE TESIS PARA OPTAR EL TÍTULO
PROFESIONAL DE INGENIERO CIVIL

Autores: Bach. Alvarado Huaman Osmer
Bach. Campos Guerrero Emerson Darley

Asesor: Dr. José Luis Piedra Tineo
Dr. Manuel Emilio Milla Pino

Línea de Investigación: LI_IC 03_ Gestión y Tecnología

JAÉN – PERÚ

MARZO , 2026

UNIVERSIDAD NACIONAL DE JAÉN
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



ESTIMACIÓN DE DAÑOS EN EL PUENTE TAMBORAPA
APLICANDO REDES NEURONALES CONVOLUCIONALES,
JAÉN - CAJAMARCA - 2025

INFORME FINAL DE TESIS PARA OPTAR EL TÍTULO
PROFESIONAL DE INGENIERO CIVIL

Autores: Egr. Alvarado Huaman Osmer
Egr. Campos Guerrero Emerson Darley

Asesor: Dr. José Luis Piedra Tineo
Dr. Manuel Emilio Milla Pino

Línea de Investigación: LI_IC03_ Gestión y Tecnología

JAÉN – PERÚ

MARZO, 2026

ÍNDICE GENERAL

1	ÍNDICE GENERAL	III
	INDICE DE TABLAS	IV
	INDICE DE FIGURAS.....	V
	RESUMEN	IX
	ABSTRACT.....	X
	I. INTRODUCCIÓN.....	11
	1.1. Descripción de la realidad problemática	11
	1.2. Justificación.....	13
	1.3. Hipótesis.....	16
	1.4. Objetivos	16
	1.5. Antecedentes	17
	II. MATERIAL Y MÉTODOS.....	24
	2.1. Ubicación geográfica.....	24
	2.2. Población.....	26
	2.3. Muestra.....	27
	2.4. Muestreo.....	28
	2.5. Métodos.....	29
	2.6. Técnicas.....	34
	2.7. Procedimiento de recolección de datos	36
	2.8. Análisis de datos.....	60
	III. RESULTADOS.....	96
	IV. DISCUSIÓN:.....	132
	V. CONCLUSIONES Y RECOMENDACIONES	139
	VI. REFERENCIAS BIBLIOGRÁFICAS.....	142
	AGRADECIMIENTO.....	153
	DEDICATORIA	154
	ANEXOS	155

INDICE DE TABLAS

Tabla 1 Datos generales del Puente Tamborapa.	24
Tabla 2 Vías De Acceso Y Tiempo De Viaje – Puente Tamborapa	26
Tabla 3 Relación de puentes y sus longitudes aproximadas	27
Tabla 4 Datos técnicos principales del Puente Tamborapa.....	28
Tabla 5 Descripción estructural y de ubicación del Puente Tamborapa	28
Tabla 6 Materiales y Equipos.....	36
Tabla 7 Equipos y materiales	37
Tabla 8 Características Principales del Dron	49
Tabla 9 Parámetros del modelo VGG16.....	77
Tabla 10 Parámetros del Modelo MobileNet.....	80
Tabla 11 Parámetros del Modelo DenseNet121	84
Tabla 12 Configuración del entorno de Entrenamiento del modelo DenseNet 121	85
Tabla 13 Parámetros del Modelo YOLO (You Only Look Once).....	89
Tabla 14 Clasificación de los daños identificados en el Puente Tamborapa	100
Tabla 15 Clasificación y severidad preliminar de los daños identificados en el Puente Tamborapa.	101
Tabla 16 Registro de imágenes capturadas mediante dron	110
Tabla 17 Arquitectura de la red neuronal convolucional VGG16 empleada para la identificación automática de fallas del Puente Tamborapa.....	111
Tabla 18 Arquitectura del modelo MobileNet empleada para la identificación automática de fallas del Puente Tamborapa.....	115
Tabla 19 Arquitectura del modelo DenseNet121 empleada para la identificación automática de fallas del Puente Tamborapa	118
Tabla 20 Arquitectura del modelo YOLO optimizado para la detección multiclase en imágenes	119
Tabla 21 Comparación del desempeño de las redes neuronales convolucionales (CNN) para la detección de daños	122
Tabla 22 Desempeño final del mejor modelo de red neuronal convolucional.....	125
Tabla 23 Resultados de validación del modelo YOLO para la detección de fallas	128

11

1

INDICE DE FIGURAS

Figura 1 Ubicación Geográfica del tramo de estudio.	25
Figura 2 Vista en planta del Puente Tamborapa.	25
Figura 3 Diagrama De FLUJO.....	30
Figura 4 Arquitectura de la red neuronal convolucional y LSTM.....	33
Figura 5 Evidencia de corrosión en la estructura del Puente Tamborapa.....	38
Figura 6 Presencia de corrosión en la estructura del Puente Tamborapa.	39
Figura 7 Presencia de fisuras en la superficie del tablero del Puente Tamborapa.....	40
Figura 8 Presencia de eflorescencia y humedad en los laterales de los estribos de la subestructura.	41
Figura 9 Presencia de eflorescencia en la parte inferior de los estribos de la subestructura. .	42
Figura 10 Evidencia de exposición de barras en la estructura del Puente Tamborapa.	43
Figura 11 Evidencia de exposición de barras en la estructura del Puente Tamborapa.	43
Figura 12 Evidencia de desplazamientos en la estructura del Puente Tamborapa.	44
Figura 13 Observación de desplazamientos en la estructura del Puente Tamborapa.	45
Figura 14 Partes del Dron DJI Mini 3Pro.	46
Figura 15 Representación del plan de vuelo mediante el dron.....	47
Figura 16 Representación del plan de vuelo mediante el dron.....	47
Figura 17 Reconocimiento del área de estudio de mediante vuelo con el equipo vant.	48
Figura 18 Batería del Dron y equipo de vuelo.....	50
Figura 19 Verificación de espacio de la tarjeta.....	50
Figura 20 Inicio del vuelo.....	51
Figura 21 Ajuste de la resolución y formato 12 MP.....	52
Figura 22 Configuración de balance de blanco, ISO.....	52
Figura 23 Activación del modo de fotometría (foto única).....	53
Figura 24 Adquisición de imágenes aéreas del Puente Tamborapa mediante dron.....	54
Figura 25 Estribo del Puente Tamborapa (vista lateral).	55
Figura 26 Barandas metálicas del Puente Tamborapa (vista lateral).....	56
Figura 27 Plataforma del Puente Tamborapa (vista superior).	57
Figura 28 Vista lateral del Puente Tamborapa.....	57
Figura 29 Apoyos del Puente Tamborapa.....	58
Figura 30 Extracción y respaldo de datos obtenidos mediante dron.....	59
Figura 31 Identificación de corrosión en elementos metálicos del Puente Tamborapa en el Software Label Studio.....	62

Figura 32 Asignación de etiquetas de corrosión en los elementos metálicos del Puente.	62
Figura 33 Identificación de grietas en la superficie del Puente Tamborapa en el Software Label Studio.	63
Figura 34 Asignación de etiquetas de grietas en la plataforma del Puente Tamborapa.	64
Figura 35 Identificación de desplazamientos en el Puente Tamborapa.	65
Figura 36 Identificación de eflorescencia en el Puente Tamborapa.	66
Figura 37 Asignación de etiquetas de eflorescencia en el Puente Tamborapa.	66
Figura 38 Identificación de exposición de barras de refuerzo en el Puente Tamborapa.	67
Figura 39 Asignación de etiquetas de exposición de barras de refuerzo en el Puente Tamborapa.	67
Figura 40 Modelo VGG16.	69
Figura 41 Modelo VGG16.	70
Figura 42 Modelo Movilnet.	71
Figura 43 Modelo Movilnet.	72
Figura 44 Modelo DenseNet121.	73
Figura 45 Modelo DenseNet121.	74
Figura 46 Modelo YOLO.	76
Figura 47 Entrenamiento del modelo VGG16.	79
Figura 48 Entrenamiento del modelo MobileNet.	82
Figura 49 Entrenamiento del modelo DenseNet121.	87
Figura 50 Creación del archivo YAML con las clases.	88
Figura 51 Entrenamiento del modelo YOLO (You Only Look Once).	90
Figura 52 Levantamiento fotográfico con dron del Puente Tamborapa.	96
Figura 53 Daños identificados en el puente Tamborapa.	97
Figura 54 Daños identificados en la superestructura del puente Tamborapa.	98
Figura 55 Daños presentes en Subestructura del puente Tamborapa.	99
Figura 56 Frecuencia observada de los daños identificados en el Puente Tamborapa.	102
Figura 57 Registro fotográfico del Puente Tamborapa mediante dron DJI Mini 3 Pro.	103
Figura 58 Imágenes recolectadas de la superestructura y subestructura.	104
Figura 59 Gráfico del Dron VANT (DJI Mini 3 Pro).	105
Figura 60 Registro fotográfico de la losa de rodadura del Puente Tamborapa.	106
Figura 61 Fallas en Barandas y bordes laterales del Puente Tamborapa.	107
Figura 62 Fallas en las Juntas de dilatación del Puente Tamborapa.	108

Figura 63 Eflorescencia en vigas, estribos y diafragmas inferiores de la subestructura del Puente Tamborapa.	109
Figura 64 Modelo CNN VGG16 para la clasificación de fallas en el puente Tamborapa. ..	113
Figura 65 VGG16 empleada para la identificación automática de fallas del Puente Tamborapa	113
Figura 66 Modelo CNN MobileNet para la clasificación de fallas en el puente Tamborapa.	114
Figura 67 Modelo CNN DenseNet121 para la clasificación de fallas en el puente Tamborapa.	117
Figura 68 Arquitectura y flujo de procesamiento del modelo YOLO para la estimación de daños en el Puente Tamborapa.	121
Figura 69 Resultados de detección de daños mediante YOLO en elementos del Puente Tamborapa	122
Figura 70 Resultados de las curvas validación de las redes neuronales convolucionales	124
Figura 71 Curvas de validación del modelo VGG16: Loss, Accuracy y F1-Score	126
Figura 72 Curvas de validación del modelo MobileNet: Loss, Accuracy y F1-Score	126
Figura 73 Curvas de validación del modelo DenseNet121: Loss, Accuracy y F1-Score.....	127
Figura 74 Matriz de confusión normalizada del modelo YOLO para la detección de patologías en estructuras de concreto.	129
Figura 75 Comportamiento de las funciones de pérdida y métricas de desempeño durante el entrenamiento del modelo YOLO.....	130
Figura 76 Curvas Precision–Confidence del modelo YOLO.	130
Figura 77 Curvas Precision–Confidence y F1–Confidence del modelo YOLO.....	131

INDICE DE ANEXOS

Anexo 1: Plano de ubicación geográfica y localización del Puente Tamborapa.....	157
Anexo 2: Ubicación del área de estudio puente Tamborapa	158
Anexo 3: Evaluación de daños de grietas y exposición de barras.	160
Anexo 4: Evaluación de daños de corrosión.	162
Anexo 5: Evaluación de daños de eflorescencia.	163
Anexo 6: Evaluación de daños de desplazamientos.	164
Anexo 7: Error, precisión y F1 score del modelo VGG16.	167
Anexo 8: Detecciones de daños con VGG16	168
Anexo 9: Real vs predicho del VGG16.....	169
Anexo 10: Error, precisión y F1 score del modelo Mobilenet.	170
Anexo 11: Detecciones de daños con MobileNet.....	171
Anexo 12: Real vs predicho de MobileNet	172
Anexo 13: Error, precisión y F1 score del modelo DenseNet121	173
Anexo 14: Detecciones de daños con DensaNet121	174
Anexo 15: Real vs predicho del DensaNet121.....	175
Anexo 16: Clases de la base de datos	176
Anexo 17: Ancho y largo de los pixeles de la base de datos.....	176
Anexo 18: Entrenamiento y validacion de YOLO	177
Anexo 19: Curva recall confidencial de YOLO.	178
Anexo 20: Curva recall de precisión de YOLO	178
Anexo 21: Curva confidencial de precisión de YOLO.....	179
Anexo 22: Curva de F1 score de YOLO.	179
Anexo 23: Matriz de confusión de YOLO.	180
Anexo 24: Detección de daños en el puente empleando YOLO.	181
Anexo 25: Detección de daños en los estribos empleando YOLO.	182
Anexo 26: Reconocimiento de daños empleando YOLO.	183
Anexo 27: clasificación de daños empleando YOLO	184
Anexo 28: Detección de daños en la plataforma del puente con YOLO.....	185

RESUMEN

El objetivo de la investigación fue estimar los daños presentes en el Puente Tamborapa mediante la aplicación de redes neuronales convolucionales (CNN). Para ello, se realizó la recolección de imágenes de la superestructura y subestructura utilizando un dron DJI Mini 3 Pro, registrándose fallas como corrosión, grietas, eflorescencia, exposición de barras y desplazamientos. Las imágenes fueron organizadas, clasificadas y etiquetadas para conformar la base de datos empleada en el entrenamiento de cuatro modelos CNN: VGG16, MobileNet, DenseNet121 y YOLO. Los resultados mostraron que las patologías más frecuentes fueron la corrosión y las grietas superficiales, identificadas principalmente en barandas metálicas, tablero y estribos. En cuanto al desempeño de los modelos, YOLO obtuvo los mejores indicadores con una precisión superior al 96%, seguido de MobileNet con 95%, DenseNet121 con 92% y VGG16 con 90%. La validación evidenció que el modelo YOLO es el más eficiente para la detección multiclase de fallas en puentes.

Se concluye que el uso de redes neuronales convolucionales constituye una herramienta eficaz y precisa para la inspección automatizada de estructuras, permitiendo reducir tiempos de evaluación, mejorar la detección temprana de daños y optimizar la gestión del mantenimiento del Puente Tamborapa.

PALABRAS CLAVE: Detección automática, CNN, Puentes, Inspección con dron, YOLO, VGG16, MobileNet, DenseNet121.

ABSTRACT

The objective of this research was to estimate the damage present in the Tamborapa Bridge through the application of convolutional neural networks (CNN). High-resolution images of both the superstructure and substructure were collected using a DJI Mini 3 Pro drone, documenting pathologies such as corrosion, cracking, efflorescence, exposed reinforcement bars, and displacements. These images were organized, classified, and labeled to create the dataset used to train four CNN models: VGG16, MobileNet, DenseNet121, and YOLO. The results showed that the most frequent damages were corrosion and surface cracking, mainly located in metallic railings, the deck slab, and abutments. Regarding model performance, YOLO achieved the highest metrics, with an accuracy above 96%, followed by MobileNet with 95%, DenseNet121 with 92%, and VGG16 with 90%. Validation demonstrated that YOLO is the most efficient model for multiclass damage detection in bridge structures.

It is concluded that convolutional neural networks represent an effective and precise tool for the automated inspection of infrastructure, reducing evaluation time, improving early damage detection, and optimizing maintenance management of the Tamborapa Bridge.

KEYWORDS: Automatic detection, CNN, Bridges, UAV inspection, YOLO, VGG16, MobileNet, DenseNet121.

I. INTRODUCCIÓN

1.1. Descripción de la realidad problemática

En lo internacional la administración de riesgos en la plataforma de puentes enfrenta grandes desafíos complejos debido a la variedad de riesgo y peligros que van desde fenómenos naturales que afrontan múltiples amenazas extremas hasta insuficiencia y errores en el mantenimiento. La insuficiencia de estándares uniformes y tecnologías avanzadas para la evaluación y supervisión o monitoreo continuo en la solidez de la estructura dificulta el reconocimiento anticipado de determinados problemas e implementación adecuada de medidas preventivas y correctivas en campo de la estructura. Esta situación conlleva peligros persistentes para la seguridad pública, pérdidas económicas significativas y obstáculos para un progreso equilibrado. De tal modo, es fundamental que la presente investigación de este campo se enfoca en la formulación de licenciamientos firmes y sólidos de monitoreo, manejo de riesgos que sean validos al alcance mundialmente. Esto contribuirá la capacidad de respuesta de las estructuras viales serán más esenciales y proteger un mejor crecimiento socioeconómico con mayor seguridad confiable y estable. Calderón (2025)

En Perú, la supervisión de deterioros en las infraestructuras en redes de transporte viales que representan desafíos cruciales debido al desgastes progresivos, en limitaciones constructivas, patologías en la estructura, influencias medioambientales y a la exposición de eventos climáticos naturales severos. Admin (2025). La Ausencia de un procedimiento coordinado completo integral y eficiente de un control de monitoreo periódico continuo en diversas evaluaciones de riesgos y convenciones eficaces anticipadas que contribuye a la creciente susceptibilidad de infraestructuras

importantes para la conectividad vial nacional y el progreso productivo en el avance socioeconómico. Pecho (2019)

Los efectos de los daños en puentes no solo ponen en peligro la seguridad de los usuarios y la operatividad del sistema vial, sino que también generan pérdidas económicas importantes como también generan disminución del rendimiento en la productividad y consecuencias económicas adversas. Esta situación problemática requiere de estrategias integradas y enfocadas que impulsen la ejecución de tecnologías avanzadas de inspección y monitoreo, con formulación de políticas estables cumpliendo normativas sólidas con una distribución eficiente de medios económicos y personal capacitado para asegurar la estabilidad y protección duradera a largo plazo de las infraestructuras viales en el país. Huamancusi Huamaní (2024)

En la región de Cajamarca, se enfrenta una situación crítica relacionado con la evaluación y administración de las afectaciones en los puentes, esencialmente para el progreso y el desarrollo regional. El desgaste de la infraestructura, las fallas en el diseño y la ejecución, así como la exposición a fenómenos ambientales y naturales como sismos y condiciones climáticas extremas, comprometen la seguridad y funcionalidad de muchos puentes en la zona.

Mosqueira Ramírez (2013). La falta de un sistema completo de inspección y monitoreo estructural en puentes dificulta la identificación temprana de fallos, lo que incrementa el riesgo de incidentes graves y eleva los costos económicos. Además, la limitada capacidad técnica y financiera local para implementar medidas preventivas de seguridad, junto con la desatención de interés por parte de las dichas autoridades, lo que genera las situaciones alarmantes que afecta negativamente el progreso social y económico en la calidad de vida de la población. Para enfrentar este desafío, es necesario desarrollar acciones puntuales y estrategias específicas que fortalezcan la

capacidad de respuesta ante emergencias, promuevan el uso de herramientas modernas con la tecnologías y mejoren la coordinación entre entidades gubernamentales y comunidades locales con el fin de asegurar la integridad ,la seguridad y durabilidad de los puentes en Cajamarca. Mascia & Sartorti (2011).

El Puente Tamborapa, ubicado en una zona montañosa, es especialmente susceptible a deslizamientos rocosos durante temporada de lluvias intensas, lo que incrementa el nivel del río y provoca inundaciones que afectan los terrenos agrícolas. Para encara los diversos tipos de desafíos, se sugiere la incorporación y adopción de herramientas avanzadas en tecnología moderna, como las redes neuronales convolucionales (CNN), con la finalidad de evaluar, mitigar y evitar las fallas en la estructura del puente.

1.2. Justificación

La presente justificación metodológica que se propone, y se busca justificar el uso de medidas reparadas y anticipadas tanto como preventivas para la gestión técnica del puente, utilizando herramientas de inteligencia artificial. De esta modalidad de trabajo ayuda a evaluar con mayor exactitud la recolección de datos sobre posibles eventuales daños en la estructura vial , lo cual permite optimizar eficientemente cada vez mejorar los recursos disponibles y administrar gastos innecesarios.

incorporar tecnología avanzadas no solo transforma el procedimiento, sino que también la manera en que se hace intervención, la cual también permite que operarios y técnicos locales adquieran nuevas competencias y habilidades. Esto mejora la eficiencia operativa frente a distintas problemáticas que se encuentran en la infraestructura vial, algo clave para las regiones como la nuestra, donde muchas veces los accesos son limitados y el tiempo de reacción es esencial. Admin (2025). Con una

evaluación exhaustiva detallada minuciosa del estado actual de estructura del puente, este método ofrece una guía clara para tomar decisiones informadas y a tiempo. La finalidad no es solo conservar o mantener el puente en un excelente y adecuado buen estado, lo cual también afianzar y garantizar su operatividad y actividad funcional con visión futura, minimizando o reduciendo amenazas mayores. Al mismo tiempo, ofrece y contribuir innovación a la mejora y avance continuo en que se gestionan este tipo de obras, generando un impacto positivo en la vida de las personas que dependen de estas vías. Zapata Castañeda (2021)

La presente justificación practica su investigación surge ante la necesidad de mantener la seguridad y salvaguardar la integridad de la conservación más efectiva en la gestión técnica en las infraestructuras de vías en esta parte de la región. A través del uso de redes neuronales convolucionales (CNN), se adquiere una alternativa de enfoque modernos para evaluar exactitud mediante automatización y precisa de forma relevante en etapas temprana, el estado estructural del puente, lo que permite reconocer deterioros y fallas antes de que se conviertan en situaciones graves y severas. Campos Barragán (2018)

Además, se proporciona un transporte más fluido y confiable que establece grandes propuestas de desarrollo beneficiando directamente a distintos centros poblacionales. La propuesta en marcha de esta tecnología avanzada innovadora lo cual brinda soluciones útiles y concretas ante circunstancias y limitaciones que puede arcionar en la infraestructura vial. En estas situaciones adversas, complicadas, impulsando desarrollo, crecimiento, seguridad y gran progreso regional, mientras se refuerza mutuamente la confianza en la red de transporte interno local. Molinari (2023)

La presente justificación teórica afirma y sostiene que el trabajo combina y articulan competencias específicas y relevantes en ingeniería civil, la inteligencia artificial y el análisis estructural, comparten una finalidad de analizar optimizar la gestión de riesgos en estructuras de obras vitales como los puentes. Se enfatiza un monitoreo permanente constante de su estado estructural, orientada para impedir colapsos y fallas graves lo cual se debe resguardar la seguridad de las comunidades locales. Los enfoques clásicos habituales y tradicionales de inspección presentan problemas y restricciones significativas en las infraestructuras. con anticipación y exactitud, en las fallas estructuras complejas sometidas a entornos climáticos adversos de la zona. Ante la situación de este cuestionario condicional, los modelos de aprendizaje profundo (CNN) surgen como una solución rápida y precisa de la tecnología avanzada, al permitir la gestión rápida de la información en grandes volúmenes de datos informativos, la detección de patrones sofisticados y la superación de debilidades asociadas a los enfoques convencionales. Analuisa-Aroca et al. (2023).

En esta justificación social la investigación se orienta en refinar un mejor manejo en el diagnóstico de afectaciones en la estructura de red vial, lo cual es un aspecto clave para preservar el bienestar, la seguridad y protección de vida de los alrededores. En el ámbito local, regional y nacional, se evidencian problemas, errores y deficiencias críticas, importantes en el cuidado técnico de estas infraestructuras, lo que representa un riesgo y peligro alto considerable, en la seguridad de los colaboradores, por falta de mecanismos confiables y eficaces de inspección continua. Esta situación puede causar colapsos y ampliarse hasta accidentes graves con consecuencias letales en la ciudadanía, además de afectar la movilidad y la conexión entre distintas zonas. Stakeholders (2025). El uso de herramientas modernas, como las (CNN), brinda la posibilidad de detectar y prever fallas y debe tomar medidas de manera preventiva,

asegurando y salvaguardando la población. En áreas como Cajamarca, Jaén y San Ignacio, donde la precariedad de la infraestructura limita el acceso a servicios básicos y frena el desarrollo local, este estudio contribuirá a mejorar la capacidad de respuesta ante emergencias y a fortalecer la resiliencia de las comunidades frente a fenómenos naturales, impulsando un entorno más seguro, funcional y sostenible. Maguiña Asis & Pascacio Zarzosa (2021)

1.3. Hipótesis

La estimación de daños en el puente Tamborapa aplicando redes neuronales convolucionales está entre un rango de 68% a 98%.

1.4. Objetivos

1.4.1. *Objetivos generales*

- Realizar la Estimación de los daños en el Puente Tamborapa aplicando redes neuronales convolucionales.

1.4.2. *Objetivos específicos*

- Identificar los daños presentes en el puente Tamborapa, tales como corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos.
- Recolectar imágenes de los daños de la super estructura y la subestructura mediante el uso de un Dron.
- Generar la red neuronal convolucional.
- Validar la red neuronal convolucional.

1.5. Antecedentes

1.5.1. Internacionales

Alfaro et al. (2025) En su artículo científico propone un enfoque innovador para identificar grietas utilizando un modelo 3D generado a partir de fotografías de un vehículo aéreo no tripulado (UAV) y el uso de una red neuronal convolucional (CNN) en el puente antiguo Villena Rey en Lima, Perú. La cual tuvo como objetivo mejorar la precisión y eficiencia de la identificación de daños basada en la inspección visual simple. Para ello utilizaron una metodología tipo práctica / de desarrollo y aplicación. Como resultados se obtuvo una precisión del **88.4%** en la detección de grietas, identificando 18 puntos de daño, de los cuales 3 resultaron ser falsos positivos. Estas tasas indican una buena precisión en la detección de los daños. Concluyendo que el modelo desarrollado mejora la eficiencia en la detección de daños en puentes existentes y puede utilizarse para identificar rápidamente el deterioro estructural, destacando la identificación de la mayor concentración de daño en el pilar izquierdo de la zona sur del puente.

Zhou et al. (2025) En su artículo científico propone un método inteligente para la detección de daños superficiales en puentes basado en vehículos aéreos no tripulados (UAVs), incorporando un proceso de detección, cuantificación y visualización en tres etapas en pruebas en una viga de concreto y un puente urbano. La cual tuvo como objetivo permitir la detección automática, cuantificación y localización de grietas en un modelo 3D del puente. Para ello utilizaron una metodología tipo práctica / de desarrollo y aplicación. Como resultados se obtuvo una precisión del 96.79% y un puntaje F1 de 88.51% en la detección de grietas, mejorando la precisión en un 3.19% y el puntaje F1 en un 3.8% en comparación con el modelo original. La precisión de la cuantificación

se mantuvo dentro del 10% del margen de error de la inspección manual tradicional. Estas tasas indican una alta precisión en la detección y cuantificación de los daños. Concluyendo que el método desarrollado mejora la eficiencia y precisión en la detección y cuantificación de daños en puentes existentes, permitiendo una visualización intuitiva del daño a través de modelos 3D.

Kaifeng et al. (2024) En su artículo científico propone un enfoque combinado para la detección de grietas en puentes, que se denomina "detección doble más segmentación simple", apoyado en aprendizaje profundo. Este enfoque toma el problema de detección y clasificación de forma incompleta debido a su complejidad y a la pequeña proporción de grietas en imágenes reales. Utilizó modelos como You Only Look Once V5(x) (YOLOV5(x)) para lograr la detección inicial y fina de grietas, y U-Net fue utilizada para la clasificación semántica. Como resultados, se obtuvo una precisión del 98,37% en la clasificación de grietas finas con U-Net. Además, YOLOV5(x) permitió tener una detección más completa y precisa. Concluyendo que el método desarrollado mejora significativamente la eficiencia y precisión en la detección de grietas en puentes, siendo útil para la detección automatizada y el mantenimiento preventivo, destacando por su enfoque combinado, lo que lo diferencia de investigaciones anteriores en el área.

Jin et al. (2023) En su artículo científico propone evaluar el uso de conjuntos de datos existentes con el fin de entrenar redes neuronales profundas (DNN) en la detección de grietas en imágenes capturadas de un UAV. Utilizando una metodología experimental, se probaron cuatro modelos DNN (U-Net, DeepLab v3 con MobileNet v3, DeepLab v3 con ResNet50, y TransUNet) entrenados con un conjunto público de 11,000 imágenes de cámaras manuales y 648 imágenes de UAV. Los resultados

mostraron que TransUNet tuvo el mejor rendimiento, con un error relativo mínimo de 6.2% y un error promedio de 16.3%. Aunque hubo una ligera disminución en la precisión al usar las imágenes de UAV, los modelos aún lograron detectar grietas efectivamente. Se concluye que, aunque el rendimiento disminuye levemente, el uso de conjuntos de datos existentes es útil para la detección de grietas en UAV, destacando la importancia de la diversidad en los datos de entrenamiento.

Chen et al. (2023) En su artículo científico de investigación tiene como objetivo establecer un sistema de aprendizaje profundo basado en una gran cantidad de datos de pruebas de puentes HSR, con el fin de desarrollar un modelo de reconocimiento automatizado de los daños en los pilares de estos puentes. Para ello utilizaron una metodología tipo experimental. Como resultados se obtuvo una tasa de reconocimiento correcto del 86% para grietas, 82% para exposición de refuerzo y 70% para desconchones de concreto en la aplicación real del modelo. Estas tasas indican una buena precisión en la detección de los diferentes tipos de daños. Concluyendo que el modelo desarrollado mejora la eficiencia en la detección de daños en los puentes HSR y puede utilizarse para identificar rápidamente el deterioro estructural. Además, se destaca la generalización del modelo de entrenamiento a imágenes fuera de muestra, lo que lo diferencia de investigaciones anteriores en el área de estudio.

Wan et al. (2022) En su artículo científico proponer establecer un método preciso y eficaz en la detección de grietas en puentes de hormigón basado en dos algoritmos, SSD de aprendizaje profundo y en el algoritmo de ocho vecinos, con el propósito de mejorar la precisión y eficiencia en la detección. En la investigación se

utilizó un enfoque aplicado, recopilando imágenes de grietas en puentes reales y en laboratorio. La base de datos incluyó más de 300 imágenes del Gran Puente Extra Grande del Gran Canal de Jing-Hang y más de 1500 imágenes de vigas de hormigón dañadas en laboratorio, fueron tomadas en diferentes ángulos y condiciones de luz. Como resultados se obtuvo una precisión superior al 95% y una sensibilidad superior al 75% al detectar grietas verticales, horizontales, inclinadas y cruzadas. concluyendo que el método propuesto supera a los métodos tradicionales en cuanto a rendimiento, mejorando la precisión y eficiencia.

Jiang et al. (2021) En su artículo científico de investigación tiene como objetivo general desarrollar y optimizar un método basado en aprendizaje profundo para la detección y clasificación rápida de daños en el concreto, centrándose en mejorar la velocidad de inferencia y la precisión de los algoritmos de detección de objetos. La metodología empleada incluye la recopilación de un gran conjunto de datos de 5000 imágenes de daños en concreto, seguido de la optimización del algoritmo de detección mediante técnicas como la convolución separable en profundidad y la estructura de embotellamiento lineal. Los resultados obtenidos muestran que el algoritmo mejorado incrementa la velocidad de inferencia en un 24.1% y 53.5% en comparación con la red original, y mejora la precisión de detección en un 3.25% y 4.04%. En conclusión, el estudio demuestra que las mejoras propuestas permiten un método más eficiente y preciso para la detección y clasificación de daños en concreto, lo cual es esencial para el mantenimiento de infraestructuras seguras.

1.5.2. *Nacionales*

Varillas et al. (2024) En su artículo científico el objetivo fue proponer un enfoque innovador para la inspección de puentes de hormigón armado con fines de mantenimiento, que involucra la reconstrucción 3D del puente y un sistema de

clasificación de daños en el hormigón basado en la gravedad. Utilizaron una metodología experimental que aplica el aprendizaje profundo para la clasificación de daños en imágenes capturadas por UAV. Los resultados obtenidos muestran una precisión de más del 90% para cada tipo de daño en el hormigón en los modelos de entrenamiento. Estos resultados indican una alta precisión en la detección de los diferentes tipos de daños. Concluyendo que esta metodología utilizada constituye un valioso aporte para automatizar y agilizar las inspecciones de puentes de hormigón, reduciendo los costos y mejorando la eficiencia a lo largo de su ciclo de vida. Además, se destaca la combinación de tecnología UAV y el método CNN para una evaluación de calidad y eficiente de la condición de los elementos de concreto en la infraestructura del puente.

Bartra Aguilar et al. (2023) En su artículo científico el objetivo principal propone detectar rajaduras en estructuras de concreto utilizando una visión artificial y técnicas de procesamiento de imágenes. La metodología utilizada en este estudio fue de tipo experimental, y el diseño se basó en la recolección de imágenes a través de una cámara de celular conectada a una laptop Asus con procesador Intel Core i5 con un sistema operativo Windows 11. Las imágenes fueron procesadas en la laptop, aplicando métodos estadísticos, para identificar anomalías, como fisuras en el tarrajeado. Los resultados obtenidos muestran una eficiencia del sistema del 93,02%. Concluyendo que la implementación del algoritmo no solo mejora la calidad y el estado del concreto, sino que también optimiza el proceso de control de producción, permitiendo de esta manera un registro diario de los datos en una base de datos almacenada, facilitando un seguimiento constante y una supervisión más efectiva de las infraestructuras, lo que conlleva a un mantenimiento preventivo y una mejor calidad de su vida útil.

Alfaro Aliaga y Arica Córdova (2021) En este artículo científico el objetivo principal propone determinar la condición estructural que presenta un puente tipo arco de tablero superior, que fue construido en 1993, y la necesidad de reforzamiento. Para ello se utilizó una metodología práctica, aplicando SCAP y LRFR, y se empleó el software CSI Bridge v22 para modelar la estructura. Durante la inspección de campo, se determinó que la condición estructural era "mala" según SCAP. Los resultados con LRFR indicaron que las cuatro columnas centrales tenían un Rating Factor inferior a 1, lo que indicó la necesidad de intervención. En cuanto a la resistencia sísmica, el puente cumplió con la normativa AASHTO LRFD Seismic Bridge Design, sin presentar problemas de desplazamientos. La intervención propuesta consistió en un encamisado con fibra de carbono SikaWrap 600, lo que aumentó un 23.13% la capacidad de carga axial de cada columna y un 38.9% el Rating Factor promedio. En conclusión, la intervención mejoraría significativamente la capacidad estructural del puente, garantizando su funcionalidad y seguridad.

Maguiña Asis (2021) En este artículo científico el objetivo principal de esta investigación fue automatizar la inspección de puentes para la detección de fisuras y vegetación usando herramientas basadas en aprendizaje profundo. Utilizaron una metodología experimental con un diseño que incluyó la implementación de dos herramientas digitales basadas en redes neuronales convolucionales (CNN), las cuales fueron aplicadas en los puentes "San Cristóbal" y "Choquechaca" como casos de estudio. En cuanto a la muestra, se procesaron un total de 100 fotogramas para el puente Choquechaca y 260 fotogramas para el puente Shupluy. Los resultados obtenidos mostraron una eficiencia del 87% para la detección de fisuras con la herramienta

DeepCrack y del 92% para la detección de vegetación con la herramienta Plant-Detection. Se concluyó que las herramientas desarrolladas mejoran significativamente la eficiencia de las inspecciones al reducir el tiempo y los recursos necesarios en comparación con los métodos convencionales. Además, se destacó que la tecnología de visión por computadora y aprendizaje profundo ofrece un alto potencial para la automatización en el mantenimiento de infraestructuras.

1.5.3. *Regional y/o Local*

Palomino Ojeda et al. (2023) En este artículo científico el objetivo principal de esta investigación fue utilizar redes neuronales convolucionales para clasificar tipos de grietas en núcleos de concreto utilizando algoritmos de aprendizaje profundo. La metodología utilizada en este estudio fue principalmente de tipo experimental, con un enfoque específico en la aplicación de técnicas de aprendizaje profundo utilizando redes neuronales convolucionales. Como resultados se obtuvieron que los modelos estudiados clasificaron correctamente el tipo de falla en concreto con precisiones de 96%, 91%, 86% y 90%, siendo el algoritmo MobileNet el mejor predictor con un 96%. En conclusión, la investigación destacó el desarrollo de algoritmos de aprendizaje profundo con diferentes arquitecturas, utilizables en la evaluación de la salud estructural como un método automatizado y confiable en comparación con los métodos tradicionales. Además, señaló que estos algoritmos entrenados podrían ser utilizados como código fuente en drones para el seguimiento estructural.

II. MATERIAL Y MÉTODOS

2.1. Ubicación geográfica

El puente Tamborapa está ubicado entre el tramo de Tamborapa y Ambato , departamento de Cajamarca, parcialmente la estructura vial se encuentra en el distrito de Bellavista provincia de Jaén a una altitud de 518 msnm, en la zona 17 de la parte ubicación geográfica de la sierra y selva alta se encuentra en una ubicación geográfica muy estratégica, ya que facilita la comunicación de transporte dentro de la ruta urbana y rural de distintos de distritos y provincias la cual se caracteriza por relieves irregulares, y con una ubicación de un clima cálido -húmedo la cual está representado desafíos para la estabilidad y el mantenimiento del puente por lo que se requiere de vigilancia continua un mejoramiento de la estructura vial con el fin de generar seguridad funcional.

Tabla 1


Datos generales del Puente Tamborapa.

Nombre del Puente	Puente Tamborapa
Localidad	Tamborapa
Distrito/provincia/Departamento	Bellavista/Jaén/Cajamarca
Coordenadas	ESTE: NORTE:
Altura	518 msnm
Zona	17

En la figura 1 y 2 se muestra la ubicación geográfica del tramo de estudio, y una vista en planta de ubicación del puente Tamborapa ubicado sobre el río Tabaconas entre el eje vial Jane San Ignacio desde la perspectiva aérea se aprecia la estructura que permite el paso vehicular y peatonal de ambos pueblos ya que la estructura es un elemento clave de la conectividad regional en una zona de características estratégicas geográficamente complejas.

Figura 1

Ubicación Geográfica del tramo de estudio.



Nota: La figura representa la ubicación referencial del tramo donde se realizó la toma de imágenes, elaborada a partir de datos de Google Earth.

Figura 2

Vista en planta del Puente Tamborapa.



Nota: La Vista en planta del Puente Tamborapa, elaborada a partir de datos de Google Earth.

2.1.1. Vías de acceso

Las vías de acceso y tiempos de traslado al Puente Tamborapa se presenta en la siguiente tabla:

Tabla 2

Vías De Acceso Y Tiempo De Viaje – Puente Tamborapa

RECORRIDO	DISTANCIA (Km)	TIEMPO (min)	TIPO DE ACCESO
Jaén – Bellavista	20.0	24	Carretera (Asfalto, rural)
Bellavista – Puerto Tamborapa	13.2	23	Carretera (Afirmada / grava)
Puerto Tamborapa – Puente Tamborapa	1.6	6	Camino local (Afirmado / vecinal)

2.2. Población

Está conformada por ocho puentes viga losa de concreto reforzados situados en la red de carreteras Jaén-San Ignacio y sus alrededores de la provincia de jaén lo cual brindan accesibilidad de la vía formado distintas conexiones entre provincias y sectores. Un puente viga-losa es una estructura de concreto armado o acero estructural, isostática o continua, que combina vigas longitudinales y transversales con una losa superior que forma el tablero. La losa y las vigas trabajan conjuntamente para transmitir las cargas a los apoyos, siendo este tipo apropiado para luces cortas-medias (aprox. 15–60 m) (Rodriguez Ruiz, 2024).

Tabla 3
Relación de puentes y sus longitudes aproximadas

Puentes	Longitud aproximada
Puente Tamborapa (mixto)",	53.57 m
Puente zeresal (losa)	16 m
“Puente los cuyes (losa)	16 m
Puente Zurunde (losa)	16 m
Puente Orellana (losa)	33 m
Puente pardo Miguel (losa)	19,60 m
Puente Manco Cápac (losa)	16.45 m
Puente pakamuros". (losa)	26 m

2.3. Muestra

El estudio se centra en el Puente Tamborapa con los presentes detalles en la siguiente. Este puente se encuentra en la intersección de las rutas C.P. Puerto Tamborapa- que forma parte del distrito de Tabaconas por la parte San Ignacio y C.P. Ambato Tamborapa-Bellavista-Jaén. La elección de este puente para el estudio se debe a que, a diferencia de los otros ocho puentes analizados, el Puente Tamborapa es el único que presenta más daños como grietas y fallas significativas. Estas características hacen que sea el candidato más adecuado para realizar un análisis exhaustivo en el proyecto de tesis, permitiendo desarrollar la “estimación de daños en el puente Tamborapa aplicando redes neuronales convolucionales.

Tabla 4*Datos técnicos principales del Puente Tamborapa*

Puente	Longitud	Altitud	km	Zona	Ruta	Departamento
Tamborapa	63.57 m	501 msnm	50+000	17	Vía jaén – san Ignacio	Cajamarca

2.3.1. Cuantificación de la muestra**Tabla 5***Descripción estructural y de ubicación del Puente Tamborapa*

PUENTE	TAMBORAPA
Tipo de estructura	MIXTO (Viga Losa)
Longitud	63.57 m
ancho	7.68 m
Altura	1.00 m
vereda	0.80 m
Altura del puente	4.00 m

2.4. Muestreo

Se empleará un muestreo intencional el cual se enfocará en el Puente número 1 que es el puente Tamborapa debido a que es uno de los nueve puentes analizados con más grietas y fallas significativas como corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos. El muestreo intencional es un método de muestreo no probabilístico, este ocurre cuando “los elementos seleccionados para la muestra son elegidos por el criterio del investigador.” Cabe mencionar que los investigadores suelen creer que pueden obtener una muestra representativa utilizando un buen juicio, lo cual resulta por supuesto en un ahorro de tiempo y dinero. Parra (2020)

Se realizará una inspección visual para identificar y documentar las anomalías, y se recogerán imágenes detalladas de las áreas afectadas. Estas imágenes servirán como base para entrenar y validar redes neuronales convolucionales, que se utilizarán para estimar los daños del puente.

2.5. Métodos

2.5.1. Método

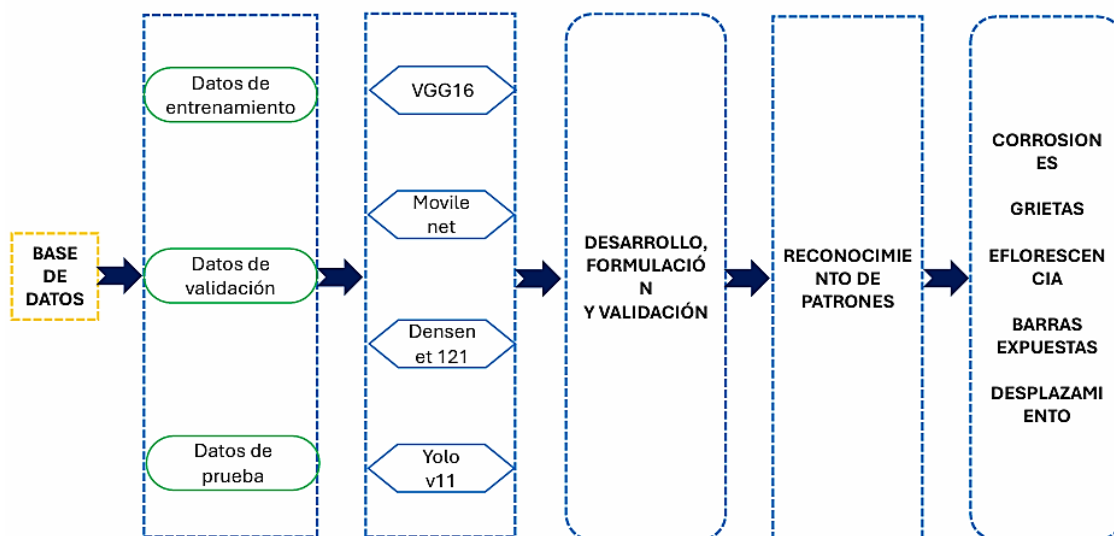
La inteligencia artificial (IA) es un campo extenso que abarca desde la filosofía hasta la ciencia y la tecnología (Gamboa, s. f.). De acuerdo a esto, la inteligencia artificial está reformada de mitos, y diversas especulaciones, y derivadas creencias en sus expectativas y esperanzas de que, mediante la ciencia y la tecnología avanza mediante aprendizaje profundo, la humanidad llegue a una nueva era de clones y autómatas fabricados directamente automatizados.

El estudio propuesto se basará en un enfoque de aprendizaje profundo supervisado para la estimación de daños en el puente Tambo rapa. En primer lugar, se recolectará todas las imágenes que sean posibles con el drone mavic y con la cámara profesional desde diferentes ángulos de la estructura de concreto a partir de esto se procederá a crear la base de datos con las imágenes obtenidas de los dispositivos usados, para determinar los tipos de fallas en el concreto, a partir de eso serán utilizadas para entrenar, validar y probar el modelo en la red neuronal convolucional. Los datos se dividirán en conjuntos o capas de entrenamiento, validación y prueba para asegurar una evaluación adecuada en diferentes etapas del proceso. Se desarrollará y se programará la arquitectura de Red Neuronal Convolucional (CNN) utilizando Yolo v 11, VGG 16, Mobilenet Dense net121. Estos modelos se entrenarán con el conjunto de datos de entrenamiento y se validarán con el conjunto de datos de validación, ajustando los hiperparámetros necesarios para optimizar el rendimiento. Una vez completado

el entrenamiento, el modelo será evaluado utilizando el conjunto de datos de prueba, midiendo su rendimiento y exactitud mediante métricas como precisión, sensibilidad y especificidad. Para acelerar el entrenamiento, se utilizará una GPU de alto rendimiento y el software incluirá bibliotecas de aprendizaje automático como Tensor Flow y Keras. La metodología será ilustrada de forma que se demuestra en el diagrama de flujo que guiará la realización del estudio. Train AI Models (2024)

Figura 3

Diagrama De FLUJO



Fuente: Palomino Ojeda et al. (2023)

2.5.1.1.VGG16

El modelo VGG16 ha sido adaptado y aplicado en el campo de la ingeniería civil para la detección automática de fallas en estructuras de concreto, especialmente grietas superficiales. En el estudio realizado por He & Zhang, (2024), se utilizó una versión mejorada de VGG16 para identificar fisuras en superficies de puentes y pavimentos, demostrando un alto nivel de precisión en la clasificación de daños. Esta adaptación confirma que VGG16 no solo es útil en reconocimiento de imágenes a gran escala, sino también en el monitoreo y diagnóstico estructural dentro de la infraestructura civil.

2.5.1.2.MOBILNETS

El modelo MobileNet es una red neuronal convolucional ligera diseñada para optimizar el uso de recursos computacionales mediante el empleo de convoluciones separables en profundidad, lo que permite reducir significativamente el número de parámetros sin comprometer la precisión. En el ámbito de la ingeniería civil, este modelo ha sido aplicado para la clasificación automática de defectos en elementos de puentes de concreto reforzado, permitiendo identificar daños como grietas, desgaste y deterioro superficial. Según el estudio de Trach, (2023), la arquitectura MobileNet demostró un rendimiento altamente eficiente, alcanzando una precisión del 94.61% en la clasificación de cuatro tipos de defectos , incluso trabajando con bases de datos complejas y variadas. Estos resultados confirman que MobileNet no solo es adecuado para aplicaciones de visión artificial en tiempo real y dispositivos de bajo consumo, sino que también constituye una herramienta efectiva y confiable para el monitoreo y diagnóstico estructural en infraestructura civil.

2.5.1.3.DENSENET 121

El modelo DenseNet-121 pertenece a la familia de Redes Convolucionales Densas, caracterizadas por establecer conexiones directas entre cada capa y todas las capas anteriores, lo que permite una propagación eficiente de las características, evita el problema del gradiente de desaparición y reduce significativamente el número de parámetros en comparación con arquitecturas convencionales más profundas. En el campo de la ingeniería civil, DenseNet-121 ha sido aplicado para la detección automática de grietas y defectos en estructuras de concreto, demostrando un desempeño notable en análisis basados en imágenes. En el estudio realizado por (Huang et al., 2018), se empleó DenseNet-121 para identificar grietas superficiales en elementos , obteniendo altas tasas de precisión y robustez, incluso ante variaciones de iluminación, textura y ruido en el material. Estos resultados confirman que DenseNet-121 es

una herramienta eficaz y confiable para el monitoreo estructural y mantenimiento predictivo en infraestructura civil.

2.5.1.4.YOLO

Entre todos los enfoques previstos, se influyen las redes neuronales convolucionales (CNN), en diversas áreas y toma de datos, las cuales se basan en algoritmos generados por la red para permitir que las máquinas permitan dar resultados efectivos e interpretar y procesar información visual de una forma que clara y precisa la cual determina a que el cerebro humano lo hace. Pujante & Benavent (2023). Las CNN constituyen un tipo de red neuronal profunda que se especializa en identificar patrones dentro de las imágenes, como contornos, texturas y formas. Gracias a la utilización de varias capas de convolución y filtrado, las CNN son capaces de extraer características importantes de las imágenes, para luego clasificarlas o predecir resultados, siendo ampliamente aplicadas en áreas como el reconocimiento de objetos, la detección de fallos y el análisis de imágenes médicas. amaiur (2024)

A. Red neuronal convolucional.

Son herramientas que constituyen instrumentos fundamentales dentro del campo del aprendizaje profundo y destacan por su alta eficacia en tareas relacionadas con el reconocimiento visual. Su funcionamiento se lleva a cabo siguiendo un proceso estructurado que se desarrolla del siguiente modo:

- 4 - Cargar y explorar los datos de imágenes.
- Diseñar la arquitectura de la red neuronal.
- Configurar las opciones de entrenamiento.
- Entrenar la red neuronal.
- Predecir las etiquetas de nuevos datos y evaluar la precisión de la clasificación.

4 Para definir cómo crear y entrenar una red neuronal de clasificación de imágenes sencilla de forma interactiva.


B. Cargar Y Explorar Datos De Imágenes

4

Carga los datos de dígitos utilizando la función “imageDatastore” y selecciona la carpeta que contiene las imágenes de mayor calidad. Un almacén de datos de imágenes simplifica la organización y gestión de grandes volúmenes de imágenes, incluso cuando no es posible almacenarlas todas en la memoria del ordenador. Esta herramienta permite cargar las imágenes en bloques durante el entrenamiento de una red neuronal, lo que hace el proceso más ágil y eficiente. Como se puede observar en la figura 4.

Figura 4

Arquitectura de la red neuronal convolucional y LSTM.



Fuente: (Rascón-Madriral, 2020)

1

El razonamiento inductivo comienza con las observaciones de los casos específicos en el cual tiene por objeto establece principales generalidades tratando de ver si cada una se aplican en casos específicos. Es por ello que este estudio es inductivo ya se inicia con puntos específicos como la toma de datos en campo mediante el uso y dron realizando el procesamiento e interpretaciones correspondientes para finalmente establecer adecuadamente las conclusiones del estudio establecido.

Este estudio fue deductivo ya que cumple funciones basadas principalmente en las bibliografías revisadas, específicamente centrados en los antecedentes hilados con el tema de

1

estudio y la observación del estado actual de la estructura vial seleccionado se concluyó que era necesario implicar esta investigación para tratar la problemática existente.

2.5.2. Tipos de investigación

El proyecto de tesis se está desarrollando de manera digital, aplicada, descriptiva y cualitativa. García-González et al. (2020) Se clasifica mediante la aplicación estadística que incluye inspección visual y la captura de imágenes con drones. Mediante el uso de redes neuronales, el proyecto permite realizar la "Estimación de daños en el puente.

Una investigación aplicada se centra en identificar diversos problemas específicos que se puede encontrar en la estructural vial mediante el empleo de conocimientos especializados para satisfacer condiciones determinadas. Según su finalidad requerida de esta investigación fue aplicada ya que centro en la utilización de nuevas metodologías y herramientas tecnológicas modernas para resolver diversos problemas relacionados con la identificación y estimación de diversas fallas en la estructura que se realizó la investigación.

1

En el enfoque cuantitativo se recolectan los datos numéricos a través de imágenes lo cual se realiza análisis estadístico para optimizar la hipótesis y establecer patrones mientras la investigación cualitativa usa la recolecta datos para precisar la investigación basándose en las preguntas perceptivas para concurrir los puntos estratégicos de los participantes

1

2.6. Técnicas

2.6.1. Observación

La observación directa constituyó como técnica principal empleada para la recopilación visual sistemática basada mediante un dron acondicionado con cámara de alta resolución, permitiendo la captación de imágenes detalladas en la superestructura y subestructura del puente Tamborapa.

Esta técnica permitió documentar las principales fallas presentes en la estructura vial, tales como corrosión del refuerzo, grietas, eflorescencia, exposición de barras y desplazamientos en juntas, estableciendo un punto visual confiable para el modelamiento, entrenamiento, validación de red neuronal convolucional.

2.6.2. Revisión documental.

Se utilizó la técnica de revisión documental para determinar los datos disponibles sobre el Puente Tamborapa, contemplando antecedentes, investigaciones precedentes, normativa vigente, metodologías de inspección y literatura académica relacionada con la detección de fallas mediante visión computacional.

Esta técnica permitió sustentar teóricamente optando establecer criterios calificados para clasificar los daños que se encontraron presentes en el puente Tamborapa, posteriormente serían ejecutados mediante los modelos VGG16, MobileNet, DenseNet121 y YOLO.

2.6.3. Procesamiento con Software

El procesamiento de imágenes que se realizó mediante el uso de software especializado, poniendo en práctica técnicas de organización y etiquetado de datos. La base de datos se dividió en modelamiento, entrenamiento, prueba y validación siguiendo parámetros de evaluación por categorías de daño.

Mediante las imágenes se desarrollaron, entrenaron y validaron los modelos de las CNN, los cuales permitieron implementar el reconocimiento automático de patrones articulados a fallas en puentes como: corrosión, grietas, eflorescencia, barras expuestas y desplazamientos. Esta técnica determinante optó por transformar la información visual generada por el VANT o dron en resultados cuantificables orientados a la estimación de daños en el puente.

2.7. Procedimiento de recolección de datos

2.7.1. Materiales y equipos

para realizar la recolección de datos se utilizó la metodología de toma de fotografías a través de un dron o un VANT (Vehículo Aéreo No Tripulado), fue necesario contar con diversos equipos y materiales.

Tabla 6

Materiales y Equipos

MATERIALES Y EQUIPOS
- Dron
- Control remoto
- 2 baterías de repuesto y cargador
- Laptop CPU Intel Core i7
- Tarjetas de memoria
- Equipos de protección personal

1 *Nota:* tabla proporciona una visión organizada de los equipos y materiales necesarios para la implementación efectiva de las metodologías.

2.7.2. Recolección de datos mediante Inspección visual tradicional del estado estructural del puente.

1 2.7.2.1. Obtención de los equipos y materiales

1 Los equipos utilizados fueron obtenidos de manera particular a través de un alquiler formal. Todos los equipos estaban debidamente calibrados y aptos lo que aseguró la precisión y fiabilidad de las mediciones tomadas y realizadas.

Tabla 7*Equipos y materiales*

Descripción	Características
Cámara	Sensor CMOS de 1/1.3" y resolución de 12 MP
Altura máx de servicio	500 m
Tiempo de vuelo	30 minutos aprox.
Peso de despegue	249 g
Rango de precisión del vuelo	Vertical ± 0.1 m, Horizontal: ± 0.1 m

2.7.2.2.Procedimiento

Esta etapa consistió en realizar el levantamiento fotogramétrico del puente vial Tamborapa que está ubicado entre el puerto del CP. Tamborapa por la parte sur y CP. Ambato Tamborapa por la parte norte con mayor referencia en carretera vial Jaén, San Ignacio en el km 50+000 ubicado a 60 minutos del centro de jaén ha dicho puente.

Los daños en estructuras viales de concreto pueden ser identificados un conjunto de fallas que limitan la capacidad de carga, resistencia, estabilidad y periodo de servicio estructural. Estos daños pueden estructurarse por diversos factores tales como el envejecimiento de los materiales, condiciones ambientales agresivas, tráfico vehicular masivo, deficiencias en el diseño, falta de mantenimiento preventivo. Según Mirboland & Smarsly, (2021), la corrosión, exposición de barras de refuerzo, la aparición de grietas, eflorescencia y el deterioro superficial son manifestaciones más frecuentes en puentes de concreto reforzado, daños que se proporcionan por falta de monitoreo oportuno, por lo que afecta significativamente la durabilidad y seguridad estructural del puente o estructura vial.

A continuación, se describen algunas de los daños comunes que pueden afectar a estas estructuras cada una del puente de estudio:


3

a. **Corrosión:** Es una de las principales causas para el deterioro de las estructuras del concreto reforzado. Sin embargo, considerar las cargas a las cuales es para lo cual se diseñan los puentes, permite tener una visión más general de las condiciones a la cual estaría sometido los puentes, por lo que este trabajo de investigación se plantea describir de manera teórica el efecto de las cargas y la corrosión sobre la estructura de puentes de concreto, sus implicaciones y como afecta tanto la vida útil (Shen et al., 2021)

En la figura 5 y 6 se muestran vistas las barandas metálicas del puente Tamborapa con gran evidencia de un avanzado proceso de corrosión superficial donde la estructura de acero presentan oxidación visible de color rojiza y con gran pérdida parcial del recubrimiento protector en gran mayoría en las zonas de las uniones de soldadura, lo cual se observa deterioro es indicativo de exposición prolongada a condiciones ambientales húmedas y lluviosas propias de la zona la cual forma el óxido de hierro.

Figura 5


Evidencia de corrosión en la estructura del Puente Tamborapa.



Nota. Fotografía de elaboración propia (2025).

Figura 6

Presencia de corrosión en la estructura del Puente Tamborapa.



Nota. Fotografía de elaboración propia (2025).

7

b. Grietas: La formación de grietas se debe a la deformación provocada por la carga medioambiental o mecánica en una pieza de hormigón reforzado o pre-tensado, y puede tener origen en muchos factores, tales como grietas por deformación de tensión o compresión (estado crítico de leve colapso); grietas originadas por esfuerzo cortante o torsión (Golewski, 2023).

La Figura 07 Se muestra la influencia en la superficie del pavimento o de la losa de rodadura sobre el tablero del Puente Tamborapa. En zonas señaladas, se perciben patrones de agrietamiento de tipo malla o llamada también piel de cocodrilo, representativo del deterioro vinculado por fatiga del material mediante la acción continua de cargas vehiculares. Estos daños se presentan de forma interconectada y se proporcionan principalmente en zonas donde el pavimento ha perdido su rigidez y capacidad de soporte.

La aparición de esta categoría de daño puede estar asociada en factores tales como el envejecimiento del asfalto y losa de rodadura, fatigas críticas, infiltración de agua y ausencia de mantenimiento preventivo. La degradación progresiva de estas áreas podría derivar en

desprendimientos, deterioros superficiales, afectación en su capacidad estructural de la losa de rodadura si no se realiza una intervención adecuada.

Los rectángulos resaltados en color amarillo señalan las zonas donde las grietas son más evidentes y se encuentran en un estado avanzado, lo cual permite establecerlas como puntos críticos para el diagnóstico y análisis posterior mediante la red neuronal convolucional.

Figura 7

Presencia de fisuras en la superficie del tablero del Puente Tamborapa.



Nota. Fotografía de elaboración propia (2025).

c. **Eflorescencia:** Es un daño superficial que aparece en estructuras vial de concreto, se particulariza mediante acumulaciones blanquecinas compuestas principalmente por sales solubles. Esta aparición se origina cuando el agua presente en el interior del concreto disuelve dichas sales por superficie de la estructura de concreto. Al evaporarse el agua, los minerales quedan cristalizados, generando manchas visibles que alteran la apariencia del material. La presencia recurrente de humedad, así como ciclos de absorción y secado, favorecen su aparición y persistencia. La eflorescencia es considerada originalmente un daño estético, la presencia es capaz de indicar una notable porosidad y permeabilidad en el concreto, lo cual allana la penetración de agentes agresivos. En efecto, este daño en la estructura puede vincularse con procesos de deterioro y disminución de la durabilidad de estructuras como muros en edificaciones y puentes de concreto reforzado (Nayır & Yılmaz, 2024)

La Figura 8 y 9 Se muestra la presencia de eflorescencia y manchas de humedad en la subestructura del Puente Tamborapa, específicamente en los muros laterales de apoyo. Se observa la formación de depósitos blanquecinos sobre la superficie del concreto, indicativos de migración de sales solubles hacia el exterior, proceso que se presenta cuando el agua penetra y atraviesa el material, disolviendo compuestos internos.

Asimismo, la coloración verdosa y los sectores con crecimiento biológico evidencian zonas con alta retención de humedad, lo cual puede estar asociado a filtraciones constantes, falta de drenaje adecuado o exposición prolongada a condiciones ambientales húmedas. Este tipo de deterioro puede favorecer la desintegración superficial del concreto con el tiempo, así como generar condiciones propicias para la corrosión de las barras de refuerzo si la humedad llega a niveles internos.

Los recuadros resaltados en color azul delimitan las áreas donde estos signos de deterioro son más notorios, identificándose como sectores críticos para su seguimiento, análisis y evaluación mediante la red neuronal convolucional en el proceso de estimación del daño estructural.

Figura 8


Presencia de eflorescencia y humedad en los laterales de los estribos de la subestructura.



Nota. Fotografía de elaboración propia (2025).

Figura 9

Presencia de eflorescencia en la parte inferior de los estribos de la subestructura.



Nota. Fotografía de elaboración propia (2025).


d. **Exposición de barras de refuerzo:** Ocurre cuando el recubrimiento de concreto que protege el acero se pierde parcial o totalmente debido a fisuración, desprendimiento (spalling) o degradación por agentes ambientales. Cuando el acero queda expuesto, se acelera el proceso de corrosión debido al ingreso de oxígeno, humedad y, especialmente, cloruros presentes en ambientes marinos o carreteras con sales. Esta corrosión reduce el diámetro efectivo de las barras y produce expansión por óxidos, lo que aumenta el daño del recubrimiento y agrava el deterioro. La pérdida de sección del acero disminuye la capacidad estructural y la ductilidad de elementos como vigas, losas y pilas. Este fenómeno es común en puentes envejecidos y en estructuras sometidas a ciclos de humedecimiento-secado. Por ello, se considera una patología crítica para la seguridad y durabilidad de puentes de concreto reforzado (Stoilova, 2024)

En la figura 10 y 11 se observa que el tablero de la estructura vial del puente se evidencia la exposición de barras de acero de refuerzo, la cual presenta una consecuencia directa de la pérdida del recubrimiento del concreto. El daño es producto de la corrosión inducida por la

humedad y agentes químicos que generan el desprendimiento del concreto circulante la erosión de la remadura compromete la resistencia estructural del tablero la cual se requiere reparación y sellado inmediata para evitar en avance del deterioro .

Figura 10

Evidencia de exposición de barras en la estructura del Puente Tamborapa.



Nota. Fotografía de elaboración propia (2025).

Figura 11

Evidencia de exposición de barras en la estructura del Puente Tamborapa.




Nota: fotografía de elaboración propia (2025)

e. **Desplazamientos:** En los puentes de concreto, los desplazamientos durante un sismo pueden ser mayores a lo previsto si el análisis estructural se basa únicamente en un comportamiento totalmente elástico. Muchos puentes antiguos fueron diseñados considerando una mayor rigidez de la que realmente presentan y con fuerzas laterales muy bajas, lo que llevó a construir apoyos con asientos cortos y poca separación entre tramos. Cuando ocurre un sismo fuerte, el puente experimenta deformaciones y movimientos más grandes, haciendo que el tablero pueda moverse fuera de su apoyo. Si este desplazamiento supera la longitud del asiento, el tablero puede caerse o separarse, generando fallas graves (Li et al., 2024).

En la figura 12 y 13 muestra la vista frontal a los estribos de tablero de la estructura vial indica desplazamiento evidente en a juntas entre ambos elementos acompañado de una fisura vertical que atraviesa la unión del concreto este tipo de daño es ocurrente por el paso vehicular constante tanto vehículos livianos como pesados a la vez asocia de algunos movimientos diferenciales del terreno con esfuerzo de empuje.

Figura 12

Evidencia de desplazamientos en la estructura del Puente Tamborapa.



Nota: fotografía de elaboración propia (2025)

Figura 13

Observación de desplazamientos en la estructura del Puente Tamborapa.



Nota: fotografía de elaboración propia (2025)

2.7.3. Recolección de imágenes de los daños de la super estructura y la subestructura mediante el uso de un Dron.

2.7.3.1. Planificación De Vuelo

Se realizó de manera planificada llevando a cabo la seguridad de cada caso tanto el área de vuelo como la vía transitable revisando el área detallada de la estructura verificando que partes del área se puede volar el VANT sin que ocurra ningún desperfecto o daños a los equipos por motivos de arbustos y obstáculos presentes para realizar toma correspondientes y adecuadas para el estudio de investigación.

En figura 14 se aprecia el equipo VANT DJI Mini 3 Pro que se empleó para sobrevolar el área de estudio, acompañado del control remoto de operación. Este VANT cuenta con una estructura ligera con un diseño aerodinámico de cuatro hélices, que garantiza una estabilidad durante el periodo de vuelo, este cuenta con sensores de visión frontal, trasera e inferior que permite navegar seguro y preciso, la planificación de vuelos, este dispositivo es empleado con el

propósito de llevar a cabo el reconocimiento fotogramétrico del área de estudio con la finalidad de obtener imágenes aéreas detalladas y ortofotos de calidad.

Figura 14

Partes del Dron DJI Mini 3Pro.



Fuente: Alderson (2021)

En la figura 15 y 16 se muestra toma de imagen de reconocimiento realizado con VANT DJI mini 3 pro sobre la estructura del puente Tamborapa ubicado en CP. Tamborapa de la provincia de jaén,

la toma permite visualizar con claridad la estructura, este vuelo permitió registrar información visual de los obstáculos o posibles zonas de riesgo con evaluación con elevación del entorno natural contribuyendo el diagnóstico técnico dentro del marco del proyecto de investigación.

Figura 15

Representación del plan de vuelo mediante el dron



Nota: fotografía de elaboración propia (2025)

Figura 16

Representación del plan de vuelo mediante el dron




Nota: fotografía de elaboración propia (2025)

En la figura 17 muestra el reconocimiento la plataforma del puente Tamborapa que tiene como finalidad realizar la toma de imágenes detalladas de la plataforma con alta calidad de visualización para determinar las fallas que se encuentran en la plataforma del puente y evitar también obstáculos que puedan perjudicar el plan de vuelo realizado con el VANT mediante la toma de datos para el proyecto de investigación.

Figura 17

Reconocimiento del área de estudio de mediante vuelo con el equipo vant.



Nota: fotografía de elaboración propia (2025)

2.7.3.2. Configuración De Parámetros Del Dron

Tabla 8

Características Principales del Dron

Característica	Valor
Peso al despegue	249 gramos
Dimensiones	Plegado: 145 × 90 × 62 mm Desplegado: 171 × 245 × 62 mm Con hélices desplegadas ~ 251 × 362 × 70 mm
Sensor de la cámara	CMOS de 1/1.3", efectivo ~48 MP
Apertura de la lente	f/1.7
Campo de visión (FOV)	~82.1° equivalente a 24 mm en formato de 35 mm
Tiempo máximo de vuelo	34 minutos con la batería estándar bajo condiciones ideales
Con batería	luz" (Intelligent Flight Battery Plus): hasta 47 minutos (en países selectos)
Velocidad horizontal máxima	hasta 4000 metros con batería estándar
Resistencia al viento:	viento de hasta ~10.7 m/s
Altitud máxima de servicio sobre el nivel del mar:	hasta 4000 metros con batería estándar; con la batería Plus algo menor (~3000 m)
Sensores de evitación de obstáculos en tres direcciones	adelante, atrás y abajo
Sistema de transmisión de video	istema O3, con hasta 12 km de alcance bajo condiciones ideales (FCC)

En la figura 18 muestra los el equipo del dron con sus respectivas baterías adicionales cargadas para realizar el trabajo de vuelo con el fin de adquirir los datos o imágenes a través de tomas con mejor fluidez y calidad sin tener retrasos por motivos de carga la cual acelera el proceso con la culminación de los requerimientos adecuados que se necesita para cumplir y formular el procedimiento adecuado que se necesita en el proyecto.

Figura 18*Batería del Dron y equipo de vuelo*

Nota: fotografía de elaboración propia (2025)

En la figura 19 observa realizando los primeros pasos que cumple con poner en marcha el proyecto prendiendo el dron y configurando los parámetros requeridos para realizar el vuelo del VANT haciendo uso del complemento adecuado del control remoto y Verificación de espacio suficiente de la tarjeta con la cual sea necesario adquirir todos los datos necesarios para llevar a cabo cada paso permitiendo iniciar el vuelo y recopilando la mayor parte de imágenes con alta calidad y fluidez.

Figura 19*Verificación de espacio de la tarjeta*

Nota: fotografía de elaboración propia (2025)

En la figura 20, 21, 22 y 23 se muestra el inicio de vuelo del dron después de haber configurado el equipo y se hace las primeras tomas verificando la calidad y el formato adecuado que se requiso para obtener los datos o recolección de imágenes, planificación de vuelo, se llevó a cabo con practica de verificación de ángulos e distintas partes de la estructura observando que no vea ningún obstáculo que pueda causar desprovistos o daños al equipo, se tomaron datos de la plataforma de los estribos y también se optó el área de aérea determinado los posibles obstáculos por parte de la vegetación presente en la orillas del rio, se tuvo en cuenta cada parámetro adecuadamente los balances ISO y configuración fotogramétrico de toda alta resolución para luego tomados los datos se descargaron en una memoria USB y luego ser procesadas de acuerdo a los siguientes pasos que planteo en el proyecto.

Figura 20
Inicio del vuelo



Nota: fotografía de elaboración propia (2025)

Figura 21

Ajuste de la resolución y formato 12 MP



Nota: fotografía de elaboración propia (2025)

Figura 22

Configuración de balance de blanco, ISO



Nota: fotografía de elaboración propia (2025)

18

Figura 23*Activación del modo de fotometría (foto única)***2.7.3.3. Adquisición de Imágenes**

Se realizó la toma de imágenes de la super estructura y sub estructura del puente, configurando los parámetros del dron tales como Ajustar la resolución y formato 12 MP, Configuración de balance de blanco, ISO, de velocidad de enfoque, Activar el modo de fotometría (foto única), mediate 90 minutos (30 minutos por batería) que se realizó el tiempo del vuelo y se exportaron las imágenes del equipo hacia una memoria USB.

La Figura 24 muestra el proceso de adquisición de imágenes aéreas del Puente Tamborapa utilizando un dron como herramienta de inspección visual. Este procedimiento permitió obtener una vista panorámica de la infraestructura y su entorno, facilitando la identificación preliminar de zonas con posibles daños tanto en la superestructura como en la subestructura.

Para la captura de las imágenes, se configuraron los parámetros del dron de manera adecuada para asegurar la calidad y nitidez de las fotografías. Se empleó una resolución de

12 MP en formato JPEG, ajustando el balance de blancos, la sensibilidad ISO y la velocidad de enfoque según las condiciones de iluminación del entorno. Asimismo, se activó el modo de fotometría (captura única) para garantizar la toma precisa de cada imagen sin interpolaciones.

El vuelo tuvo una duración aproximada de 90 minutos, durante los cuales se cubrió el puente desde diferentes ángulos y alturas, permitiendo obtener una colección de imágenes detalladas que posteriormente fueron exportadas a una memoria USB para su organización, análisis y procesamiento en el modelado mediante redes neuronales convolucionales.

Figura 24

Adquisición de imágenes aéreas del Puente Tamborapa mediante dron.



Nota: fotografía de elaboración propia (2025)

La Figura 25 muestra uno de los estribos del Puente Tamborapa, correspondiente a la subestructura de la obra. Se aprecia el paramento del estribo construido de concreto, el cual presenta zonas con manchas de humedad y desarrollo de vegetación superficial, y posible presencia de filtraciones. El estribo está en contacto directo con el cauce del río y con la vegetación que lo rodea, lo que puede favorecer el desgaste de la estructura debido a la

erosión superficial, la acumulación de humedad y el crecimiento de plantas y hongos en la zona.

También se observó una tubería adyacente a la estructura, posiblemente destinada al drenaje, pero sin protección o sujeción visible, lo que podría generar desprendimientos durante las crecidas del río. La inspección de esta zona es importante para verificar el estado del concreto, el funcionamiento del drenaje y la posible socavación en la base del estribo, factores que pueden afectar la estabilidad de la infraestructura, según lo señalado en el Manual de Inspección de Puentes – MTC (2019).

Figura 25

Estribo del Puente Tamborapa (vista lateral).



Nota: fotografía de elaboración propia (2025)

La Figura 26 muestra el estado actual de las barandas metálicas del Puente Tamborapa, las cuales forman parte de los elementos de seguridad vial de la superestructura. En la imagen se observa que las barandas presentan signos visibles de deterioro, especialmente en la zona inferior del anclaje, donde el concreto de apoyo muestra desprendimientos y fisuras asociadas a la acción de agentes climáticos y posibles impactos mecánicos.

Asimismo, se aprecia corrosión superficial en los tubos metálicos horizontales y verticales,

evidenciada por la presencia de manchas de óxido y pérdida parcial del recubrimiento protector. Este proceso de oxidación, combinado con la falta de mantenimiento periódico, puede comprometer la integridad estructural y la capacidad de contención de las barandas ante eventuales colisiones.

La inspección detallada de estos elementos es necesaria para determinar el grado de corrosión, evaluar la adherencia del concreto en los puntos de anclaje y establecer medidas de rehabilitación o sustitución que garanticen la seguridad de los usuarios del puente.

Figura 26

Barandas metálicas del Puente Tamborapa (vista lateral).



Nota: fotografía de elaboración propia (2025)

La figura 27 muestra una vista aérea de la plataforma del Puente Tamborapa, correspondiente al tablero de la superestructura. Se observa el tablero vehicular compuesto por losa de concreto, que constituye la superficie de rodadura para el tránsito vehicular. Se distinguen líneas de fisuración longitudinal en la superficie del pavimento, posiblemente asociadas a fatiga del material o movimientos diferenciales del tablero.

A ambos extremos del puente se observan los accesos y estribos, con revestimiento en las márgenes del cauce, lo que contribuye a la protección frente a procesos erosivos.

Figura 27

Plataforma del Puente Tamborapa (vista superior).



Nota: fotografía de elaboración propia (2025)

La Figura 28 presenta una vista lateral del Puente Tamborapa, donde se observa la superestructura de concreto armado que sostiene el tablero vehicular. La estructura se apoya sobre pilas intermedias y estribos en los extremos, los cuales permiten la adecuada transmisión de cargas hacia el terreno de cimentación. El puente se encuentra ubicado sobre un cauce de río Tabaconas su estructura está conformada por las barandas metálicas laterales muestran presencia de corrosión superficial, evidenciando exposición de barras a condiciones climáticas y falta de mantenimiento

Figura 28

Vista lateral del Puente Tamborapa.



Nota: fotografía de elaboración propia (2025)

La Figura 29 se observan los apoyos ubicados entre la viga principal y la pila (o estribo), los cuales cumplen la función de distribuir las cargas verticales y controlar desplazamientos horizontales. El estado de los apoyos es de especial importancia, dado que su deterioro puede generar esfuerzos adicionales en la superestructura y afectar el comportamiento dinámico del puente como deformación, desplazamiento o pérdida de alineación. y evidencia de humedad o acumulación de sedimentos.

Figura 29

Apoyos del Puente Tamborapa



Nota: fotografía de elaboración propia (2025)

2.7.3.4.Descarga De Datos

Se realizó la transferencia de los datos capturados por el dron desde la tarjeta de memoria hacia un dispositivo USB de almacenamiento temporal. Posteriormente, la información contenida en el USB fue copiada y respaldada en una laptop segura y autorizada, con el fin de garantizar la integridad de los archivos y continuar con el proceso de análisis correspondiente a la investigación.

La Figura 30 Presenta el proceso de extracción de datos capturados durante la inspección del Puente Tamborapa. Después del vuelo del dron sobre el puente y realizadas la toma de imágenes de la superestructura y subestructura, los archivos fueron transferidos desde la memoria interna del dron hacia una unidad de almacenamiento USB.

Se aseguró la integridad y disponibilidad de las imágenes electromagnéticas respaldando y organizando el registro. Posterior a su clasificación, preprocesamiento y análisis dado el desarrollo de la red neuronal convolucional. En este sentido, la gestión de los datos es de vital importancia a los fines de lograr un set de entrenamiento de calidad que permita resultados fiables en la etapa de estimación.

Figura 30

Extracción y respaldo de datos obtenidos mediante dron.



Nota: fotografía de elaboración propia (2025)

2.8. Análisis de datos

2.8.1. Generación la red neuronal convolucional.

Para esta etapa, la Red Neuronal Convolucional fue desarrollada para la estimación de daños en estructuras del Puente Tamborapa, como se adecua al objetivo general de aplicar técnicas de IA para el proceso de reconocimiento automatizado de daños en la infraestructura del Puente Tamborapa.

El modelo se diseñó y entrenó utilizando un conjunto de imágenes recogidas a partir de un dron que retrató los diferentes tipos de daños en las superestructuras y subestructuras del puente. La CNN arquitectura de en este caso fue configurado para procesar y aprender patrones visuales asociados a corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos, permitiendo la identificación precisa y sistemática de cada tipo de deterioro.

Durante el entrenamiento se ajustaron los hiperparámetros y los pesos, además el desempeño del modelo fue evaluado a través de la precisión, la sensibilidad y la exactitud. Esto garantiza su funcionamiento adecuado y que los resultados se obtengan fueran confiables para el análisis estructural.

2.8.2. Pre procesamiento de imágenes

El procesamiento previo de las imágenes fue una etapa esencial en el flujo de trabajo, ya que debía proporcionar suficiente calidad y coherencia a los datos para que la CNN pudiera entrenarse con ellos. Usando las imágenes tomadas por el dron, las descarté, las clasifiqué y las segmenté según el tipo y la gravedad de los daños identificados en las propias estructuras.

A cada imagen se le aplicaron que estuviera normalizada, redimensionada, brillante y contrastada de manera que sus características visuales fueron óptimas para un análisis computarizado. A demás, se aplicaron las técnicas de aumento de los datos (data

augmentation) para ampliar el conjunto de entrenamiento y mejorar la capacidad de la generalización del modelo frente a distintas condiciones de iluminación, textura o ángulo de captura.

2.8.2.1.Fallas identificadas

a. Corrosión

Dentro de las patologías identificadas, la corrosión es una de las más representativas y críticas para el Puente Parral-Marcavalle. Este fenómeno puede ser identificado principalmente en los elementos metálicos de la superestructura, barandas y refuerzos expuestos, en los que la oxidación del acero indica la acción de la humedad y agentes ambientales agresivos por un tiempo prolongado.

La Figura 31 y 32 se muestra el proceso de identificación y etiquetado de zonas con evidencia de corrosión en los elementos de la baranda del Puente Parral-Marcavalle. Este proceso fue realizado a través del programa Label Studio, en el marco de la etapa de estimación de daños. En las imágenes se aprecian múltiples áreas resaltadas en color rojo que indican la presencia de corrosión superficial y pérdida de recubrimiento protector en los tubos y uniones metálicas de la baranda. Estas zonas han sido clasificadas y registradas para su posterior análisis cuantitativo dentro del proyecto de diagnóstico estructural.

Figura 31

Identificación de corrosión en elementos metálicos del Puente Tamborapa en el Software Label Studio.



Nota: La figura representa el proceso de etiquetado identificando la corrosión de los elementos metálicos, elaborada mediante la Software Label Studio (2025)

Figura 32

Asignación de etiquetas de corrosión en los elementos metálicos del Puente.



Nota: La figura representa la asignación de las etiquetas de corrosión en los elementos metálicos del Puente, elaborada mediante el Software Label Studio (2025)

b. Grietas

La Figura 33 y 34 se muestra el procedimiento de detección y etiquetado de grietas en la superficie del tablero del Puente Tamborapa, realizado mediante la plataforma Label Studio como parte del proceso de preprocesamiento de imágenes y entrenamiento de la red


neuronal convolucional (CNN).

En la imagen se observa la delimitación automática de zonas afectadas por fisuración, las cuales han sido clasificadas en diferentes regiones marcadas en color rojo.

Todas las áreas rojas inspeccionadas presentan grietas longitudinales y transversales en la capa de rodadura del puente debido a factores como la fatiga del material, retracción del concreto y las cargas de tráfico repetidas, entre otros. El etiquetado sistemático de tales fisuras involucra básicamente un conjunto estructurado de datos que facilita la realización de la práctica de aprendizaje supervisado por parte de la CNN, para lograr una detección automática más precisa del problema.

Figura 33


Identificación de grietas en la superficie del Puente Tamborapa en el Software Label Studio.



Nota: La figura representa el proceso de etiquetado e identificando de grietas en la superficie del Puente, elaborada mediante la Software Label Studio (2025)

Figura 34

Asignación de etiquetas de grietas en la plataforma del Puente Tamborapa.



Nota: La figura representa la asignación de las etiquetas de grietas en la superficie del Puente, elaborada mediante la Software Label Studio (2025).

c. Desplazamientos

La Figura 35 el proceso de detección y etiquetado de desplazamientos en la estructura del Puente Tamborapa, realizado a través de la plataforma Label Studio como parte de la etapa de estimación de daños. Tal y como se aprecia en la imagen, se ha procedido a la delimitación de zonas específicas en las que se evidencia la ocurrencia de desplazamientos o desalineaciones de los elementos, como fisuras con separación diferencial o ligeros cambios en la altura en la superficie del tablero. Dichas áreas fueron etiquetadas de manera que se pudiera documentar su localización y magnitud, siendo parte del total de subconjuntos y datos empleados para el entrenamiento de la Red Neuronal Convolutiva (CNN).

Figura 35

Identificación de desplazamientos en el Puente Tamborapa.



Nota: La figura representa el proceso de etiquetado identificando los desplazamientos en la estructura del Puente, elaborada mediante la Software Label Studio (2025).

d. Eflorescencia

La Figura 36 y 37 Presenta el proceso de detección y etiquetado en el área con presencia de eflorescencia en partes del concreto en el Puente Tamborapa, utilizando la herramienta tecnológica de Label Studio como parte del procedimiento de estimación de daños por intermedio de la visión computacional.

En la imagen se reconoce áreas resaltadas que se observa marcas o manchas blanquecinas o cristalizaciones salinas sobre el asfalto del puente, la eflorescencia es causada por la migración de sales solubles a través de los poros del material que se dan mediante filtraciones de agua o por causa de lluvias. Este hecho es común en estructuras expuestas a la humedad constante o a filtraciones, y también se le considera un indicador de permeabilidad y posible degradación superficial del concreto.

Las zonas con más daños fueron delimitadas y clasificadas para su incorporación en el conjunto de datos de entrenamiento de la Red Neuronal Convolutiva (CNN), lo que permite su verificación automática y participa en el estado integral del estado de

conservación del puente.

Figura 36
Identificación de eflorescencia en el Puente Tamborapa.



Nota: La figura representa el proceso de etiquetado identificando la eflorescencia en los elementos del concreto del Puente, elaborada mediante la Software Label Studio (2025).

Figura 37
Asignación de etiquetas de eflorescencia en el Puente Tamborapa.



Nota: La figura representa el proceso de asignación de etiquetas de eflorescencia en los elementos del concreto del Puente, elaborada mediante la Software Label Studio (2025).

e. Exposición De Barras

La Figura 38 y 39 representa el proceso de la detección y etiquetado de área afectada

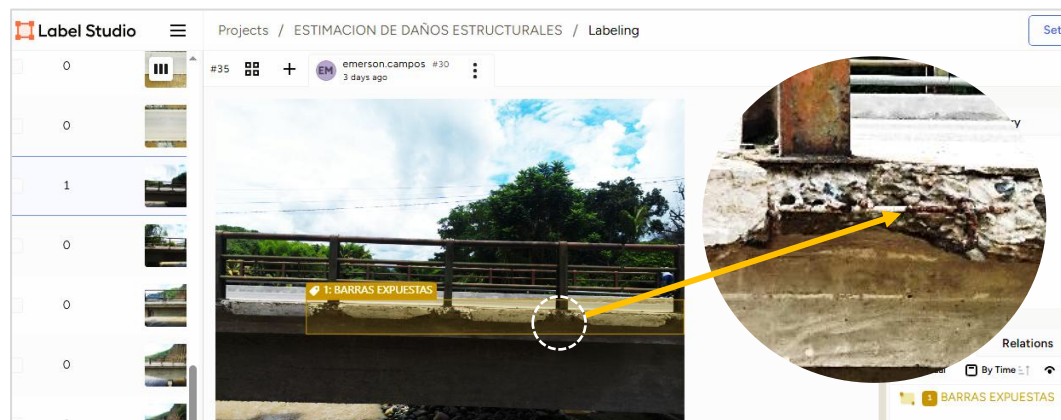
de daños de exposición de barras de refuerzo en los componentes del Puente Tamborapa, ejecutado mediante la plataforma Label Studio dentro del mecanismo de estimación de daños .

En la imagen se reflejan áreas resaltadas que indican la desgaste del recubrimiento de concreto y la presencia de exposición directa del acero de refuerzo, causa del proceso de fisuración, desprendimiento superficial y corrosión avanzada. Esta categoría de daños representa una patología estructural de alta severidad, que compromete la adherencia entre el acero y el concreto, disminuyendo gran parte de la capacidad resistente del puente.

Las áreas más identificadas fueron precisadas y clasificadas según la magnitud del daño, siendo integradas en el conjunto de datos utilizados para el entrenamiento de la Red Neuronal Convolutiva (CNN).

Figura 38

Identificación de exposición de barras de refuerzo en el Puente Tamborapa.



Nota: La figura representa el proceso de etiquetado e identificación de barras expuestas en los elementos de del Puente, elaborada mediante la Software Label Studio (2025).

Figura 39

Asignación de etiquetas de exposición de barras de refuerzo en el Puente Tamborapa.



Nota: La figura representa la asignación de etiquetas de barras expuestas en los elementos de del Puente, elaborada mediante la Software Label Studio (2025).

2.8.3. Modelos CNN

a. Modelo VGG16

El modelo VGG16 consta de 16 capas, abordado por capas convolucionales, de agrupación (max pooling) y ligadamente conectadas (fully connected). Su arquitectura se caracteriza por disponer bloques de capas convolucionales seguidos de capas de pooling, culminando mediante una serie de capas densas que realizan la categorización ejecutada. La arquitectura reduce relevantemente el número de parámetros con similitud a otros modelos anteriores, optimizando gradualmente la eficiencia en la detección de características útiles para procedimientos como clasificación de imágenes (Qassim et al., 2018)

Figura 40

Modelo VGG16

```
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")

model = models.vgg16(weights=models.VGG16_Weights.IMAGENET1K_V1)

model.classifier = nn.Sequential(
    nn.Linear(model.classifier[0].in_features, len(classes)),
    nn.Sigmoid()
)
model = model.to(device)

Downloading: "https://download.pytorch.org/models/vgg16-397923af.pth" to /root/.cache/torch/hub/checkpoints/vgg16-397923af.pth
100%|██████████| 528M/528M [00:03<00:00, 147MB/s]
```

La Figura 41 muestra la arquitectura del modelo VGG16, se empleó para la estimación de daños en el puente Tamborapa.

El modelo consta de: (a) una capa de entrada que adquiere las imágenes de los daños del puente en formato (224×224) píxeles y colores RGB; (b) está constituido mediante 13 capas convolucionales con filtros de tamaño 3×3 y función de activación ReLU, gestoras de extraer las características más relevantes; (c) capas MaxPooling con ventanas de 2×2, que ajustan progresivamente las dimensiones espaciales de las imágenes; (d) presentan tres capas totalmente conectadas, donde la primera contiene 4096 neuronas con activación ReLU, y la última utiliza la función Softmax para clasificar los tipos de daños .

En este caso, la red clasifica las imágenes en cinco categorías: corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos, permitiendo un análisis automatizado y preciso del estado estructural del puente Tamborapa.

Figura 42*Modelo Movilnet*

```
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")

model = models.mobilenet_v2(weights=models.MobileNet_V2_Weights.IMAGENET1K_V1)

model.classifier = nn.Sequential(
    nn.Linear(model.classifier[1].in_features, len(classes)),
    nn.Sigmoid()
)
model = model.to(device)
```

Downloading: "https://download.pytorch.org/models/mobilenet_v2-b0353104.pth" to /root/.cache/100%|██████████| 13.6M/13.6M [00:00<00:00, 141MB/s]

La Figura 43 representa la arquitectura del modelo Movilnet, que si bien se utilizado para la estimación de daños en el puente Tamborapa, que se encuentra ubicado en las provincias de san Ignacio- jaén en la región Cajamarca. Este modelo permitió identificar diferentes tipos de deterioro presentes en la superestructura y subestructura del puente mediante el procesamiento automático de imágenes capturadas con dron.


El modelo consta de las siguientes etapas: (a) una capa de entrada, que recibe las imágenes de los elementos del puente Tamborapa, procesadas en una matriz de 224×224 píxeles con canal de color RGB; (b) la información es procesada por capas convolucionales separables en profundidad, las cuales aplican convoluciones 1×1 para optimizar el cálculo y reducir la complejidad computacional; (c) las capas residuales de cuello de botella (Bottleneck Residual) reducen la dimensionalidad de los datos antes de aplicar las operaciones convolucionales, disminuyendo así el número de canales y la carga de cómputo requerida; (d) posteriormente, la información se transmite a la capa Average Pooling (Ave-Pool), donde se obtiene el promedio de las características más relevantes de las imágenes; (e) finalmente, la capa completamente conectada (FC) realiza la clasificación de los daños presentes en el puente, basándose en las características extraídas por las capas anteriores. En este caso, la capa FC está configurada con cinco neuronas de salida, correspondientes a las clases: corrosión, grietas, eflorescencia, exposición de barras de refuerzo y

desplazamientos.

Esta arquitectura permite generar, entrenar y validar una red neuronal convolucional eficiente para la detección y clasificación de daños en infraestructuras de concreto, contribuyendo al diagnóstico estructural del puente Tamborapa y al mantenimiento preventivo de sus componentes principales. (Howard et al., 2017)

Figura 43

Modelo Movilnet



c. Modelo DenseNet121

El entrenamiento del modelo DenseNet121 se realizó ajustando sus capas para extraer características relevantes de las imágenes. La arquitectura está compuesta por bloques densos donde la salida de cada bloque que se concatena con las entradas, promoviendo la reutilización de características y reduciendo el riesgo de sobreajuste. Para mejorar el rendimiento, se empleó transferencia de aprendizaje, utilizando pesos preentrenados en ImageNet, y se realizó un ajuste fino con un número reducido de épocas, adaptando el modelo a la tarea específica de clasificación de daños en el puente Tamborapa. Además, se configuró en la plataforma Google Colab con GPU para acelerar el proceso de entrenamiento y obtener mejores resultados (Huang et al., 2017).

Figura 44*Modelo DenseNet121*

```
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")

model = models.densenet121(pretrained=True)
model.classifier = nn.Sequential(
    nn.Linear(model.classifier.in_features, len(classes)),
    nn.Sigmoid() # multi-label
)
model = model.to(device)

... /usr/local/lib/python3.12/dist-packages/torchvision/models/_utils.py:208: UserWarning:
  warnings.warn(
/usr/local/lib/python3.12/dist-packages/torchvision/models/_utils.py:223: UserWarning:
  warnings.warn(msg)
Downloading: "https://download.pytorch.org/models/densenet121-a639ec97.pth" to /root/.
100%|██████████| 30.8M/30.8M [00:00<00:00, 122MB/s]
```

La Figura 45 muestra la arquitectura del modelo DenseNet121, implementado para la estimación de daños en el puente Tamborapa. Este modelo permitió procesar y clasificar las imágenes capturadas mediante el dron, identificando los principales tipos de fallas presentes en los elementos del puente.


El modelo consta de las siguientes etapas: (a) una capa convolucional inicial (Conv), encargada de extraer la información y las características básicas de las imágenes de los daños ; (b) la información se envía a una capa de agrupación máxima (MaxPool), que permite reducir la dimensionalidad de las características iniciales, conservando los rasgos más relevantes; (c) a continuación, los datos se procesaron en cuatro bloques densos (Dense Blocks 1, 2, 3 y 4), conformados por múltiples capas convolucionales conectadas en serie. La salida de cada capa se concatena con la entrada de todas las capas siguientes dentro del mismo bloque, generando una conexión directa entre capas que mejoraron el flujo de información y la reutilización de características aprendidas en etapas anteriores; (d) entre los bloques densos se incorporaron varias capas de transición convolucionales, que permitieron reducir la complejidad computacional y controlar el tamaño de la red; (e) posteriormente, la información se dirige a la capa de agrupación promedio (AvePool), que

disminuye el número de características antes de la etapa de clasificación; (f) finalmente, las capas completamente conectadas (FC) se encargan de clasificar los tipos de daños presentes en el puente Tamborapa, utilizando las características extraídas por las capas previas.

En este caso, el modelo DenseNet121 clasifica las imágenes en cinco categorías de daños : corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos. Esta arquitectura se distingue por su alta eficiencia en el uso de parámetros y su capacidad para mantener un flujo de información constante, lo que la convierte en una herramienta eficiente para el diagnóstico automatizado del estado estructural del puente Tamborapa.

Figura 45

Modelo DenseNet121



d. Modelo YOLO

El modelo YOLO (You Only Look Once) es una red neuronal convolucional moderna diseñada para la detección y clasificación de objetos en una sola pasada sobre la imagen. A diferencia de los modelos tradicionales que requieren múltiples etapas, YOLO realiza la detección en tiempo real, combinando eficiencia y precisión. Su arquitectura se

17

14

divide en tres componentes principales: backbone, neck y head.

El backbone se encarga de extraer las características relevantes de la imagen mediante capas convolucionales y de agrupación; el neck (basado en estructuras como FPN o PAN) fusiona características de diferentes niveles de la red para mejorar la detección de objetos de distintos tamaños; y la head genera las predicciones finales, que incluyen las coordenadas de los *bounding boxes*, el nivel de confianza y la clase correspondiente.

Este modelo integra módulos avanzados como ELAN y C2f, que optimizan la propagación de información y reducen el costo computacional, además de emplear técnicas de escalado compuesto para equilibrar la profundidad, el ancho y la resolución del modelo. Estas mejoras permiten un rendimiento más estable y preciso en entornos con recursos limitados, como drones o dispositivos de borde (L. He et al., 2025).

1. Cargar el modelo

```
model = YOLO("yolov12n.pt")
```


La Figura 46 muestra la arquitectura del modelo YOLO, utilizado para la estimación de daños en el puente Tamborapa. El modelo se compone de: (a) una capa de entrada que recibe las imágenes del puente tomadas por dron, representadas en formato de color RGB; (b) una serie de capas convolucionales (Conv Layer) y capas de agrupación (MaxPool), encargadas de extraer y reducir las características visuales relevantes de cada imagen; (c) un backbone profundo que aprende patrones complejos asociados a los daños del Puente; (d) un neck que combina la información de diferentes niveles de la red para mejorar la detección de daños en distintas escalas; y (e) una capa de salida (head) que predice simultáneamente las posiciones y categorías de los daños .

El modelo YOLO clasificó los daños en cinco categorías principales: corrosión, grietas,

eflorescencia, exposición de barras de refuerzo y desplazamientos. Debido a su capacidad de detección en tiempo real y alta precisión, resulta especialmente útil para el análisis automatizado del estado estructural del puente Tamborapa, permitiendo una identificación eficiente y rápida de las zonas afectadas.

Figura 46

Modelo YOLO



2.8.4. Entrenamiento de la CNN

2.8.4.1. Entrenamiento del Modelo VGG16

a. Preparación de los Datos

Durante la fase de entrenamiento del modelo VGG16, se aplicaron técnicas de aumento de datos (data augmentation) para mejorar la capacidad de la red para generalizar ante diferentes condiciones de captura. Según (Shorten & Khoshgoftaar, 2019), la ampliación sintética del conjunto de imágenes contribuye a reducir el sobreajuste y aumenta la robustez del modelo. Entre estas técnicas se emplearon transformaciones como

redimensionamiento de imágenes, rotación aleatoria y volteo horizontal, además de la normalización estandarizada según los parámetros de ImageNet.

Las imágenes corresponden a cinco tipos de daños identificados en el Puente Tamborapa cómo corrosión, desplazamientos, exposición de barras de refuerzo, eflorescencia y grietas.

El conjunto de datos se dividió en 80% de entrenamiento y 20% de validación.

lo que permitió evaluar el comportamiento del modelo sobre muestras no utilizadas durante la fase de aprendizaje, siguiendo las recomendaciones metodológicas indicadas por (Hussain et al., 2024).

b. Configuración de la Red e Hiperparámetros

El modelo VGG16 se empleó con pesos preentrenados en ImageNet, como punto de partida para transfer learning, permitiendo que la red aprendiera características generales de las imágenes antes de adaptarlas a las fallas específicas del Puente Tamborapa.

Se utilizó la arquitectura VGG16 preentrenada en ImageNet, lo que constituye un enfoque de *transfer learning*. Este procedimiento permite reutilizar características visuales previamente aprendidas por la red en grandes bases de datos, optimizando la eficiencia del entrenamiento en dominios específicos (Simonyan & Zisserman, 2015).

Se modificó la capa final del modelo para producir una salida multietiqueta, implementando una capa Sigmoid por clase y empleando la función de pérdida Binary Cross Entropy (BCELoss).

Tabla 9

Parámetros del modelo VGG16

Parámetro	Valor
-----------	-------

Tamaño de imagen	224×224 píxeles
Función de pérdida	Binary Cross Entropy (BCELoss)
Optimizador	Adam
Learning Rate	0.0001
Épocas	50
Batch Size	16
Métrica de evaluación	F1-Score (macro)

Estas configuraciones permitieron equilibrar el rendimiento del modelo y el costo computacional, favoreciendo la identificación tanto de patrones locales (grietas finas) como globales (corrosión o eflorescencia).

c. Procedimiento de Entrenamiento

El entrenamiento se realizó de forma supervisada, alimentando la red con imágenes etiquetadas según el tipo de falla como corrosiones, grietas, eflorescencias, barras expuestas y desplazamientos.

Durante cada época, se monitorearon, la pérdida de entrenamiento y validación, la precisión multi-etiqueta, y el puntaje F1 macro promedio. Este último fue fundamental para evaluar el desempeño del modelo en clases con distribución desigual y evitar la dependencia exclusiva de la exactitud, la cual puede ser engañosa en problemas con desbalanceo de datos (Goodfellow et al., 2016).

d. Configuración del Entorno

El entrenamiento se ejecutó en Google Colaboratory sobre un sistema con GPU NVIDIA Tesla T4 (8 GB de VRAM), utilizando PyTorch 2.0.0, Python 3.9, y CUDA 11.1.

Hussain et al., (2024) destacan que el uso de GPU es esencial para acelerar el entrenamiento de redes convolucionales, dado el alto costo computacional del procesamiento de imágenes.

Figura 47

Entrenamiento del modelo VGG16

```
from sklearn.metrics import f1_score
import numpy as np

criterion = nn.BCELoss()
optimizer = optim.Adam(model.parameters(), lr=1e-4)

def train_model(epochs=5):
    for epoch in range(epochs):
        model.train()
        train_loss = 0.0
        train_preds = []
        train_labels = []

        for imgs, labels in train_loader:
            imgs, labels = imgs.to(device), labels.to(device)

            optimizer.zero_grad()
            outputs = model(imgs)
            loss = criterion(outputs, labels)
            loss.backward()
            optimizer.step()

            train_loss += loss.item() * imgs.size(0)

            train_preds.append((outputs > 0.5).float().cpu().numpy())
            train_labels.append(labels.cpu().numpy())
```

2.8.4.2. Entrenamiento del modelo MobileNet

a. Preparación de los Datos

Para el entrenamiento del modelo MobileNet, se utilizó la misma base de imágenes recolectadas de la estructura del puente, clasificadas en categorías como, corrosiones, grietas, eflorescencia, exposición de barras y desplazamientos. Antes de iniciar el

entrenamiento, todas las imágenes fueron redimensionadas a 224×224 píxeles, normalizadas y convertidas a formato tensor.

Además, se aplicaron técnicas de *data augmentation* para mejorar la capacidad de generalización del modelo ante variaciones reales de iluminación, perspectiva y distancia, se aplicaron técnicas de *data augmentation*, tales como: rotación aleatoria, volteo horizontal y ajustes leves de orientación. Estas técnicas permiten incrementar la variabilidad del conjunto sin necesidad de recolectar más imágenes, lo cual es fundamental en proyectos donde la captura en campo es limitada (Goodfellow et al., 2016).

El conjunto se dividió en 80% para entrenamiento y 20% para validación

b. Configuración de la Red y Hiperparámetros

Se utilizó el modelo MobileNetV2 pre-entrenado en ImageNet, aplicando la técnica de transfer learning, lo cual permitió reutilizar patrones visuales previamente aprendidos y adaptarlos a las imágenes de fallas en el Puente Tamborapa (Sandler et al., 2019).

El clasificador final fue reemplazado por una capa densa con cinco neuronas, correspondiente a las cinco clases definidas, y una función de activación Sigmoid, ya que se trata de un problema de clasificación multietiqueta (varios tipos de daño pueden aparecer simultáneamente en la misma imagen).

Tabla 10

Parámetros del Modelo MobileNet

Parámetro	Valor aplicado
-----------	----------------

Tamaño de imagen	224 × 224 px
Optimizador	Adam
Épocas	50
Batch size	16
Learning rate	0.0001
Función de pérdida	Binary Cross-Entropy (BCELoss)

Estos valores se seleccionaron para permitir una convergencia estable evitando el sobreajuste, ya que MobileNet es ligero y eficiente, especialmente adecuado para aplicaciones con limitación computacional y posible implementación en dispositivos móviles o drones (Sandler et al., 2019).

c. Procedimiento de Entrenamiento

El modelo fue entrenado en un esquema de aprendizaje supervisado, minimizando la función de pérdida BCELoss, típica en escenarios multi-etiqueta. Durante cada iteración, los pesos de la red se ajustaron mediante el algoritmo de optimización Adam.

Para controlar el riesgo de sobreajuste, se aplicaron las siguientes estrategias:

- Validación cruzada periódica, comparando desempeño en entrenamiento y validación.
- Data augmentation, para aumentar la variabilidad de muestras.
- Monitoreo de métricas, principalmente accuracy y F1-Score, esta última útil en conjuntos desbalanceados.

d. Configuración del Entorno de Entrenamiento

El proceso de entrenamiento se ejecutó en Google Colab, con soporte de GPU, empleando el framework PyTorch:

- GPU NVIDIA (Colab)
- Python 3.9
- PyTorch 1.13
- CUDA habilitada

Esta configuración permitió entrenar MobileNet de forma eficiente, aprovechando su bajo costo computacional.

Figura 48

Entrenamiento del modelo MobileNet

```
from sklearn.metrics import f1_score
import numpy as np

criterion = nn.BCELoss()
optimizer = optim.Adam(model.parameters(), lr=1e-4)

def train_model(epochs=5):
    for epoch in range(epochs):
        model.train()
        train_loss = 0.0
        train_preds = []
        train_labels = []

        for imgs, labels in train_loader:
            imgs, labels = imgs.to(device), labels.to(device)

            optimizer.zero_grad()
            outputs = model(imgs)
            loss = criterion(outputs, labels)
            loss.backward()
            optimizer.step()

            train_loss += loss.item() * imgs.size(0)

        train_preds.append((outputs > 0.5).float().cpu().numpy())
        train_labels.append(labels.cpu().numpy())
```

2.8.4.3. Entrenamiento del Modelo DenseNet121

a. Preparación de los Datos

Para entrenar el modelo DenseNet121, se empleó el mismo conjunto de imágenes obtenidas durante la inspección del puente, clasificadas en categorías como corrosiones, grietas, eflorescencia, exposición de barras y desplazamientos. Todas las imágenes fueron redimensionadas a 224×224 píxeles y normalizadas siguiendo el estándar de entrada utilizado en modelos preentrenados de visión por computadora.

Para mejorar la capacidad de generalización del modelo se aplicó data augmentation, aplicando técnicas de aumento de datos como rotación aleatoria, volteo horizontal y recorte aleatorio, lo que aumentó la variabilidad de las imágenes y contribuyó a la mejora de la capacidad de generalización del modelo frente a diferentes ángulos y condiciones de toma de fotografías de la estructura.

Además, se aplicaron técnicas de *data augmentation*, tales como rotación aleatoria, volteo horizontal y recorte aleatorio, con el propósito de incrementar la variabilidad del conjunto de datos y mejorar la capacidad de generalización del modelo frente a diferentes condiciones de iluminación y ángulos de captura. Estas técnicas permitieron reducir el sobreajuste y mejorar el desempeño ante variaciones reales en campo.

El conjunto de datos se dividió en 80% para entrenamiento y 20% para validación.

b. Configuración del Modelo y Hiperparámetros

DenseNet121 se caracteriza por sus conexiones densas, donde cada capa recibe como entrada los mapas de características de todas las capas anteriores, favoreciendo el flujo eficiente de información y gradientes. (Huang et al., 2017). Durante las primeras etapas del entrenamiento, las capas convolucionales base se mantuvieron congeladas, modificándose únicamente la cabeza de clasificación final para adaptarla a las clases propias del puente Tamborapa.

Los hiperparámetros utilizados se describen en la siguiente tabla:

Tabla 11
Parámetros del Modelo DenseNet121

Parámetro	Valor aplicado
Tamaño de imagen	224 × 224 px
Optimizador	Adam
Épocas	50
Batch size	16
Learning rate	0.0001
Función de pérdida	Cross-Entropy Loss

c. Descripción de los Hiperparámetros

- **Tamaño de imagen (224×224 px):** Se estableció el tamaño estándar utilizado en modelos preentrenados en ImageNet, lo que permite mantener la compatibilidad con los pesos base de DenseNet121.
- **Optimizador Adam:** Seleccionado por su capacidad de ajustar dinámicamente la tasa de aprendizaje para cada parámetro, favoreciendo una convergencia más estable que métodos tradicionales como SGD.
- **Épocas:** El modelo fue entrenado durante 50 épocas, garantizando que el modelo tuviera suficientes iteraciones para aprender patrones relevantes en las imágenes sin incurrir en sobreajuste.
- **Batch size:** Se empleó un tamaño de lote de 16, lo que significa que en cada iteración del entrenamiento se procesaron 16 imágenes antes de actualizar los pesos del modelo.
- **Learning rate:** Se utilizó una tasa de aprendizaje inicial de 0.0001, la cual controla la magnitud de los ajustes realizados a los pesos durante el proceso de optimización.

- **Función de pérdida:** Adecuada para problemas de clasificación multiclase, ya que cuantifica la discrepancia entre la clase predicha y la clase real.

d. Procedimiento de Entrenamiento

El entrenamiento se realizó de manera supervisada utilizando la función de pérdida Cross-Entropy Loss, adecuada para problemas de clasificación multiclase. La actualización de los pesos se efectuó mediante retropropagación, utilizando el optimizador Adam.

La normalización de las imágenes se realizó utilizando los valores estándar del conjunto ImageNet (mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]), lo que permitió adaptar correctamente los datos al dominio en el que DenseNet121 fue originalmente entrenado.

e. Configuración del Entorno

El entrenamiento se efectuó en Google Colab con aceleración por GPU, según se detalla a continuación:

Tabla 12

Configuración del entorno de Entrenamiento del modelo DenseNet 121

Componente	Descripción
GPU utilizada	NVIDIA Tesla T4 (16 GB VRAM)
CPU utilizada	CPU virtual Intel Xeon
Framework de entrenamiento	PyTorch y Torchvision
Versión de Python	Python 3.9
Bibliotecas de soporte	CUDA

f. Descripción del Entorno:**- Unidad de Procesamiento Gráfico (GPU): NVIDIA Tesla T4**

La GPU fue utilizada para acelerar las operaciones matriciales y convolucionales propias del entrenamiento de redes neuronales profundas.

- Unidad de Procesamiento Central (CPU): Intel

El CPU se encargó de la administración de procesos, lectura de datos y operaciones no paralelizables.

- Framework de Deep Learning: PyTorch 2.0.0 con Torchvision.

El modelo fue implementado en **PyTorch**, debido a su flexibilidad, eficiencia en el manejo de tensores y soporte nativo para entrenamiento acelerado en GPU.

- Lenguaje de Programación: Python 3.9.

Python fue utilizado debido a su compatibilidad con librerías modernas de visión por computadora y aprendizaje profundo.

- Aceleración por Hardware: CUDA 11.1.

CUDA permitió la integración entre PyTorch y la GPU, habilitando el procesamiento paralelo masivo durante el entrenamiento.

Figura 49

Entrenamiento del modelo DenseNet121

```
from sklearn.metrics import f1_score
import numpy as np

criterion = nn.BCELoss()
optimizer = optim.Adam(model.parameters(), lr=1e-4)

def train_model(epochs=5):
    for epoch in range(epochs):
        model.train()
        train_loss = 0.0
        train_preds = []
        train_labels = []

        for imgs, labels in train_loader:
            imgs, labels = imgs.to(device), labels.to(device)

            optimizer.zero_grad()
            outputs = model(imgs)
            loss = criterion(outputs, labels)
            loss.backward()
            optimizer.step()

            train_loss += loss.item() * imgs.size(0)

        train_preds.append((outputs > 0.5).float().cpu().numpy())
        train_labels.append(labels.cpu().numpy())
```

2.8.4.4. Entrenamiento del Modelo YOLO

a. Preparación de los Datos

Durante la fase de entrenamiento, se utilizaron técnicas de aumento de datos (data augmentation), incluyendo rotaciones, traslaciones, espejado horizontal y vertical, así como ajustes de brillo y contraste, con el objetivo de mejorar la robustez del modelo frente a variaciones en iluminación, ángulo de captura y condiciones ambientales. Estas transformaciones permiten mejorar la robustez del modelo ante cambios en iluminación, distancia y ángulo de toma, aumentando la capacidad generalizadora sin necesidad de incrementar el tamaño del dataset (L. He et al., 2025).

La base de datos se dividió en un conjunto de entrenamiento de 1720 imágenes (80%) y un conjunto de validación de 430 imágenes (20%).

Luego, el modelo fue ajustado a la base de datos mediante un entrenamiento supervisado, utilizando el archivo de configuración `data.yaml`, que contenía la estructura de las clases y las rutas de las imágenes para entrenamiento, validación y prueba. El entrenamiento se realizó durante 50 épocas, un número adecuado para alcanzar la convergencia sin incurrir en sobreajuste.

Se creó el archivo `data.yaml` para definir las rutas de las imágenes de *train* y *val* y el listado de clases:

Figura 50

Creación del archivo YAML con las clases

```
import yaml
import os
data = {
    'path': r"C:\Users\Usuario\Videos\Deteccion de fallas estructurales\datasets",
    'train': 'images/train',
    'val': 'images/val',
    'test': 'images/test',
    'names': {
        0: "Corrosión",
        1: "Desplazamientos",
        2: "Eflorescencia",
        3: "Exposición de barras de refuerzo",
        4: "Grietas"
    }
}

# Ruta de salida para el archivo YAML
output_dir = r"C:\Users\Usuario\Videos\Deteccion de fallas estructurales\datasets"
output_file = os.path.join(output_dir, "data.yaml")

# Guardar el archivo YAML
with open(output_file, 'w') as file:
    yaml.dump(data, file, default_flow_style=False, sort_keys=False)

print(f"Archivo YAML guardado en: {output_file}")
```

Posteriormente, se llevó a cabo el entrenamiento supervisado sobre la base de datos, configurada mediante el archivo `data.yaml`, el cual contenía la definición de las tres clases (buenos, sucios/flameados y rotos) y las rutas a los conjuntos de imágenes de entrenamiento, validación y prueba. El proceso fue ejecutado durante 50 épocas, con un

tamaño máximo de imagen de 640 píxeles, lo que representó un balance entre detalle visual y costo computacional.

b. Configuración de la Red

Se utilizó Google Colaboratory en un sistema operativo Windows 11; la GPU es NVIDIA RTX 3070ti con 8 G de memoria de vídeo; la CPU es Intel i7, empleando PyTorch 2.0.0, Python 3.9 y CUDA 11.1. Para garantizar una gran eficacia del entrenamiento, se establecieron los siguientes hiperparámetros:

- 8 - **Batch size:** Para el entrenamiento, se empleó un batch size de 16. Esto significa que 16 imágenes serán utilizadas por iteración, para actualizar los parámetros de la CNN.
- 8 - **Momentum:** Es un parámetro que permitió minimizar los cambios en los pesos entre lotes, ya que solo se procesa una pequeña porción de la imagen en cualquier momento.
- 8 - **Learning rate:** Indica que tan rápido un batch está aprendiendo. El valor asignado para la red fue de 0.01.

Tabla 13

Parámetros del Modelo YOLO (You Only Look Once)

Parámetros	Valores
Image sizes	640x640 px
Optimizer	Adam
Epoch	50
Batch size	14
Learning rate	0.01
Weight decay	0.0005
Momentum	0.937

La tasa de aprendizaje inicial del entrenamiento se fijó en 0.01; el lote de entrenamiento en 16; el coeficiente de decaimiento del peso en 0.0005; el coeficiente de impulso se fijó en 0.937; y las rondas de iteración se configuraron en 50.

Figura 51

Entrenamiento del modelo YOLO (You Only Look Once)

```
# Entrenar el modelo
results = model.train(data="C:\\Users\\Usuario\\Videos\\Deteccion de fallas estructurales\\datasets\\data.yaml", # Ruta al archivo YAML
                      epochs=50, # Número de iteraciones
                      imgsz=640, # Tamaño de las imágenes (máxima dimensión)
                      plots=True, # Guardar gráficos de entrenamiento
                      )

optimizer: AdamW(lr=0.001111, momentum=0.9) with parameter groups 113 weight(decay=0.0), 120 weight(decay=0.0005), 119 bias(decay=0.0)
Image sizes 640 train, 640 val
Using 8 dataloader workers
Logging results to runs\\detect\\trains
Starting training for 50 epochs...
```

Epoch	GPU_mem	box_loss	cls_loss	df1_loss	Instances	Size
1/50	3.37G	2.122	3.784	1.666	3	640: 100% ██████████ 41/41 [03:36<00:00, 5. mAP50 mAP50-95): 100% ██████████ 4/4 [00:06<0
	Class	Images	Instances	Box(P	R	
Epoch	GPU_mem	box_loss	cls_loss	df1_loss	Instances	Size
2/50	3.41G	2.027	2.685	1.578	7	640: 100% ██████████ 41/41 [04:47<00:00, 7. mAP50 mAP50-95): 100% ██████████ 4/4 [00:10<0
	Class	Images	Instances	Box(P	R	
Epoch	GPU_mem	box_loss	cls_loss	df1_loss	Instances	Size
3/50	3.44G	1.994	2.338	1.589	7	640: 100% ██████████ 41/41 [03:34<00:00, 5. mAP50 mAP50-95): 100% ██████████ 4/4 [00:05<0
	Class	Images	Instances	Box(P	R	

2.8.5. Validación y evaluación del CNN

La evaluación del desempeño de los modelos implementados se realizó utilizando métricas ampliamente aceptadas en el campo de la visión por computadora y el aprendizaje profundo. Estas métricas permiten analizar la capacidad del modelo para identificar correctamente los diferentes tipos de daños registrados en el Puente Tamborapa, tales como corrosiones grietas, eflorescencia, exposición de barras y desplazamientos.

Durante la validación de los modelos, se evaluó el desempeño sobre un conjunto de datos no visto durante el entrenamiento, con el objetivo de medir la capacidad de generalización del sistema. Según Alshammari, (2022), el proceso de validación es fundamental para determinar si el modelo aprende patrones reales de las imágenes o simplemente memoriza los datos de entrenamiento (sobreajuste).

Asimismo, Addisu et al., (2025) destaca que en tareas de clasificación de deterioros , donde la cantidad de ejemplos por clase puede ser variable, es necesario emplear métricas que consideren el equilibrio entre clases, ya que la exactitud (accuracy) por sí sola puede ser engañosa. Por este motivo, además de la precisión (Precision) y la exhaustividad (Recall), se calcularon el **F1-score** y la **Balanced Accuracy**, lo cual permitió obtener una evaluación más justa del rendimiento del modelo.

2.8.5.1. Fundamento Matemático de las Métricas

Antes de definir las métricas, se consideran cuatro posibles resultados en cada predicción:

- TP (True Positive): daño correctamente identificado.
- TN (True Negative): ausencia de daño correctamente identificada.
- FP (False Positive): se detecta daño donde no lo hay.
- FN (False Negative): el modelo no detecta un daño existente.

A continuación, se describen las métricas utilizadas en este proyecto, acompañadas de su interpretación técnica, utilidad en ingeniería civil y la explicación de cada término matemático que las compone.

a. Exactitud (Accuracy)

La exactitud es una de las métricas más empleadas en la evaluación de modelos de clasificación. Representa la proporción de predicciones correctas respecto al total de evaluaciones realizadas. En el contexto de inspección y mantenimiento de puentes, esta métrica permite tener una primera aproximación del rendimiento general del modelo, reflejando cuántas veces se acertó al determinar si existía o no una falla visible sobre los elementos . Sin embargo, diversos autores advierten que, si bien el Accuracy puede ser intuitivo, no siempre

es totalmente representativo en problemas con desbalance de clases, como ocurre cuando algunas patologías (por ejemplo, grietas finas) son más frecuentes que otras, como la exposición de barras (Goodfellow et al., 2016).

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Parámetros de la fórmula:

- **TP (True Positive):** Predicciones correctas en las que el modelo detectó una falla que realmente estaba presente.
- **TN (True Negative):** Predicciones correctas donde el modelo determinó que no existía daño en la imagen.
- **FP (False Positive):** Casos en los que el modelo indicó una falla inexistente (falsa alarma).
- **FN (False Negative):** Situaciones donde existía daño real, pero el modelo no lo identificó, lo cual puede ser crítico en términos de seguridad.

b. Precisión (Precision)

La precisión indica qué tan confiables son las detecciones positivas realizadas por el modelo, es decir, cuántas de las fallas señaladas realmente son correctas. Esta métrica es importante cuando se busca evitar falsas alarmas, ya que estas pueden generar inspecciones y costos innecesarios. En el mantenimiento de infraestructura, una alta precisión permite confiar en que cada vez que el sistema señale la presencia de una patología, esta tendrá una alta probabilidad de ser real (Szeliski, 2022).

$$\text{Precision} = \frac{TP}{TP + FP}$$

Parámetros:

- **TP:** Cantidad de fallas correctamente detectadas.
- **FP:** Cantidad de detecciones que el modelo marcó como daños sin serlo.

Una precisión alta significa que cuando el modelo indica que existe daño, es muy probable que realmente lo haya. Es útil para minimizar falsas alarmas (Szeliski, 2022)

c. Sensibilidad o Recall (Recall)

La sensibilidad o Recall mide la capacidad del modelo para localizar fallas reales. Esto es especialmente relevante en inspecciones , donde no detectar un daño puede representar un riesgo significativo para los usuarios y disminuir la vida útil del puente. Mangalathu et al., (2020) destacan que las omisiones en la identificación de daños pueden acelerar el deterioro y aumentar el costo de los trabajos de reparación, o incluso comprometer la estabilidad de la estructura.

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

Parámetros:

- **TP:** Fallas correctamente identificadas.
- **FN:** Fallas reales que el modelo no logró detectar.

En inspecciones , esta métrica es crítica, pues no detectar un daño puede comprometer la seguridad (Mangalathu et al., 2020)

d. Medida F1 (F1-score)

El F1-score combina la Precisión y el Recall en un equilibrio expresado como su media armónica, siendo especialmente útil en casos donde existe desbalance de clases. Esta métrica ayuda a evitar resultados inflados artificialmente cuando el modelo solo aprende a predecir clases mayoritarias. Chollet, (2018) señala que el F1-score permite evaluar modelos de forma más realista, especialmente cuando la seguridad estructural depende de la detección correcta de fallas poco frecuentes.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Parámetros:

- **Precision:** Proporción de detecciones correctas sobre todas las detecciones positivas.
- **Recall:** Proporción de daños reales correctamente detectados.

Es útil cuando existe un desbalance de clases, porque evita que el modelo obtenga buenos resultados artificialmente (Chollet, 2018)

e. mAP (Mean Average Precision) - Para YOLO

El mAP es la métrica más utilizada en modelos de detección de objetos, como YOLO, ya que evalúa la precisión de las detecciones y la correcta localización mediante umbrales de intersección entre la predicción y la realidad (IoU). Lin et al., (2014) establecen que el mAP resume el desempeño del modelo en todos los tipos de daño, convirtiéndose en un indicador estándar para evaluar la eficacia de sistemas de visión computacional aplicados a infraestructura.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

Parámetros:

- **AP_i (Average Precision de la clase i):** Precisión promedio para una clase, considerando múltiples valores de IoU.
- **N:** Número total de clases evaluadas (en este caso, los diferentes tipos de daño del puente).

Corresponde al promedio de la precisión calculada a múltiples umbrales de intersección entre predicción y realidad (IoU).

Es el estándar internacional para evaluar modelos de detección (Lin et al., 2014)


III.RESULTADOS

3.1.Daños presentes en el puente Tamborapa.

Durante el reconocimiento de daños en el Puente Tamborapa, se realizó un registro visual y se tomó fotos tanto de la superestructura como de la subestructura. Se consideró elementos clave como vigas, losa de rodadura, zonas de apoyo, barandas, juntas y estribos. Para identificar las fallas en el puente se usaron criterios habituales en la inspección de estructuras de concreto, siguiendo lo que indica la Directiva N° 01-2006-MTC/14 “Guía Para Inspección De Puentes” La inspección dejó en claro varias alteraciones físico-mecánicas. Muchas estuvieron relacionadas con la exposición prolongada a la humedad y a agentes químicos (sales y cloruros), y sobrecargas de los vehículos, que han provocado desplazamientos en la estructura.

Figura 52

Levantamiento fotográfico con dron del Puente Tamborapa.



Nota: La figura presenta el proceso de levantamiento visual y fotográfico de la superestructura y subestructura del puente Tamborapa. (2025)


La figura 53 muestra fotos de los daños que se encontró durante la inspección visual del Puente Tamborapa. Ahí se ven los problemas principales: corrosión, grietas, eflorescencia, barras de acero a la vista y algunos desplazamientos.

Estos daños están tanto en la superestructura como en la subestructura. La eflorescencia aparece sobre todo en zonas con filtraciones y humedad acumulada. En cambio, la corrosión y el acero expuesto aparecen donde el concreto perdió su recubrimiento, así que el material termina enfrentándose directamente al ambiente. Las grietas tienen distintas formas y tamaños. Algunas vienen de sobrecargas, otras de la retracción del concreto, y otras más por fallas en el diseño o falta de mantenimiento.

Sobre los desplazamientos, notamos que en ciertos tramos el puente ya perdió su alineamiento.

Figura 53

Daños identificados en el puente Tamborapa.



Nota. La figura presenta un resumen visual de las fallas registradas en el Puente Tamborapa. (Elaboración propia, 2025).

3.1.1. Hallazgos por zonas del puente

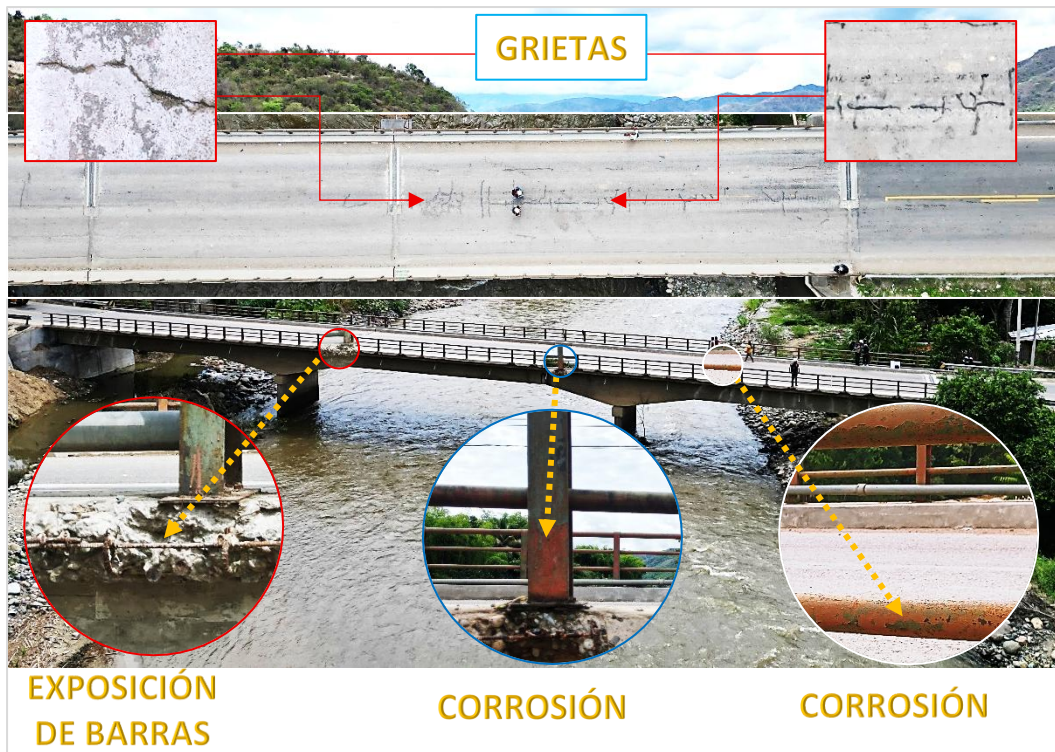
a. Superestructura

En la superficie de rodadura se observaron grietas transversales y longitudinales, sobre todo cerca de las juntas. En algunas zonas, se ven barras de acero expuestas y humedad constante. Al revisar la cara inferior de la losa y las vigas, se encontraron áreas con corrosión activa, reconocibles por las manchas, la eflorescencia y el desprendimiento progresivo del recubrimiento.

La figura 54 muestra de forma clara los daños principales que afectan la superestructura del Puente Tamborapa. Ahí se aprecian grietas longitudinales y transversales en la losa de rodadura, además de corrosión y barras de refuerzo expuestas en los elementos metálicos y en los bordes del tablero. Estas fallas se relacionan tanto con el impacto de los agentes ambientales como con el flujo constante del río, que mantiene la humedad, acelera la carbonatación y favorece la degradación superficial de la estructura.

Figura 54

Daños identificados en la superestructura del puente Tamborapa.



Nota. La figura muestra la ubicación y el tipo de daños hallados en la superestructura del Puente Tamborapa: grietas, corrosión y exposición de barras de refuerzo (Elaboración propia, 2025).

b. Subestructura (estribos y apoyos)

Se verificó la presencia de eflorescencia en puntos con filtraciones y escurrimientos prolongados. Asimismo, se observaron desplazamientos en las zonas de apoyo, lo que sugiere una necesidad de estudio de estabilidad a futuro.

La figura 55 muestra los principales daños identificados en la subestructura del puente Tamborapa, donde se evidencia la presencia de desplazamientos en los apoyos y juntas, así como áreas afectadas por eflorescencia, indicativa de filtración de agua y migración de sales hacia la superficie del concreto. Estos daños se encuentran asociados al contacto permanente con el flujo del río, así como a la posible degradación de los materiales por procesos físico-químicos y variaciones térmicas propias de la zona.

Figura 55

Daños presentes en Subestructura del puente Tamborapa.



Nota. La figura representa los daños identificados en la subestructura del Puente Tamborapa, con el propósito de resaltar las áreas afectadas por eflorescencia y desplazamientos (Elaboración propia, 2025).

3.1.2. Registro y clasificación de daños identificados

En el puente Tamborapa se llevó una clasificación de fallas en que la estructura vial se desarrolló de acuerdo a estándares aceptados en la ingeniería estructural, la cual se tomó como los datos más aceptables y comprobables que podemos encontrar las fallas tales como (corrosión, grieta, eflorescencia, exposición de barras y desplazamiento).

La clasificación de fallas en el puente Tamborapa se desarrolló de acuerdo con definiciones comúnmente aceptadas que se va menciona en la tabla 14

Tabla 14

Clasificación de los daños identificados en el Puente Tamborapa

Daño identificado	Descripción resumida de la evidencia
Corrosión	Presencia de manchas marrones, desprendimiento del recubrimiento y pérdida de sección metálica.
Grietas	Grietas en diferentes direcciones, algunas activas, con aperturas estimadas entre 1 y 2 cm de ancho.
Eflorescencia	Formación de cristales blanquecinos en superficie, sugerente de paso de agua a través de la matriz cementicia.
Exposición de barras	Pérdida de recubrimiento y acero visible en zonas de borde y puntos de escurrimiento.
Desplazamientos	Desniveles entre losas y deformaciones menores en zonas cercanas a juntas y estribos.

Nota. Datos obtenidos a partir de la inspección visual y registro fotográfico del Puente Tamborapa (Elaboración propia, 2025).

La tabla 15 se muestra cada descripción de los daños identificados en el Puente Tamborapa durante la inspección visual fallas tales como (corrosión, grietas, eflorescencia, exposición de barras de refuerzo y desplazamientos), indicando frecuencia, ubicación predominante y severidad estimada. Los resultados muestran que la corrosión y la exposición de barras se presentan principalmente en zonas inferiores y bordes del puente (barandas metálicas), mientras que las grietas son más frecuentes en la losa de rodadura(asfalto). Asimismo, la eflorescencia apareció en áreas con mayor humedad en este caso por el sector de los estribos, y los desplazamientos se localizaron en juntas y transiciones de la estructura.

Tabla 15

Clasificación y severidad preliminar de los daños identificados en el Puente Tamborapa.

Patología o tipo de falla	Frecuencia observada	Ubicación predominante	Severidad estimada
Corrosión	900	Vigas y placas inferiores de la superestructura	Media – Alta
Grietas	390	Losa de rodadura y bordes del tablero	Baja – Media
Eflorescencia	400	Estribos y zonas de acumulación de humedad	Baja
Exposición de barras de refuerzo	300	Bordes erosionados y juntas deterioradas	Media – Alta
Desplazamientos	100	Juntas de dilatación y zonas de transición	Baja


Nota. Datos obtenidos mediante inspección visual directa y análisis fotográfico realizado en el Puente Tamborapa (Elaboración propia, 2025).

La Figura 56 muestra con qué frecuencia aparecen las diferentes fallas en el Puente Tamborapa. El gráfico de barras muestra con claridad que la corrosión domina por completo, con unos 900 casos registrados. Luego vienen la eflorescencia y las grietas con cerca de 400 y

390 casos cada una. La exposición de barras de refuerzo suma unas 300 veces, y los desplazamientos son los menos comunes, con unos 100 registros. Esta representación facilita ver qué daños se repiten más y cuáles son realmente críticos, por lo tanto, resulta evidente la necesidad de priorizar las intervenciones en las zonas más afectadas por la corrosión. y la exposición del refuerzo.

Figura 56

Frecuencia observada de los daños identificados en el Puente Tamborapa.



3.2 Imágenes recolectadas de los daños de la superestructura y la subestructura mediante el uso de un dron.

Para la captura de los registros fotográficos del Puente Tamborapa, se empleó un dron equipado con cámara de alta resolución fotográfica de 48 MP (8064 × 6048 px), lo que permitió obtener imágenes desde perspectivas imposibles de alcanzar mediante inspección únicamente terrestre.

La figura 57 muestra el proceso de levantamiento de vuelo para la captura de imágenes aéreas del Puente Tamborapa mediante el uso de un dron DJI Mini 3 Pro, el cual permitió obtener imágenes 8064×6048 pixeles visuales de zonas de la superestructura y subestructura que no son accesibles mediante observación directa desde el nivel de la vía, proporcionando vistas aéreas y laterales de alta precisión para la identificación de daños como corrosión, grietas, eflorescencia, desplazamientos y exposición de barras .

Figura 57

Registro fotográfico del Puente Tamborapa mediante dron DJI Mini 3 Pro.



Nota. La imagen muestra el proceso de obtención de fotografías aéreas del puente utilizando un dron DJI Mini 3 Pro. Elaboración propia (2025).


Las actividades se llevaron a cabo el 21 de junio de 2025, un sábado por la mañana, de 9 a 11. Durante esas dos horas, se usó un dron para tomar fotos del Puente Tamborapa. Se logró una visión clara y completa del puente y de todo lo que lo rodea. Gracias al dron, se pudo ver detalles que normalmente son imposibles de revisar, como la parte inferior de la losa de rodadura, zonas internas de las vigas y los apoyos centrales.

Con este método, se logró imágenes de alta resolución del tablero, las barandas, los estribos y los elementos inferiores. Así, evitamos exponer al equipo a riesgos innecesarios y mejoramos la calidad del levantamiento visual, como recomienda Seo et al. (2018) en inspecciones asistidas por vehículos aéreos no tripulados en infraestructura vial.

En la figura 58 se muestra la toma de Imágenes realizadas en el puente Tamborapa, datos que fueron necesarias para la ejecución del proyecto teniendo en cuenta los parámetros establecidos y evaluados según los pasos que se han realizado en cada parte del proceso de toma de datos con el VANT.

Figura 58

Imágenes recolectadas de la superestructura y subestructura



En cuanto a las condiciones operativas realizadas con el VANT (DJI Mini 3 Pro). Se evidencio la configuración y las características del dron las cuales tubo como finalidad una operatividad muy factible y eficiente tanto en la visualidad y calidad de toma de fotometría de la estructura vial teniendo en cuenta el área libre que se pudo registrar.

Figura 59

Gráfico del Dron VANT (DJI Mini 3 Pro).

**3.2.1 Sectores inspeccionados y cobertura fotográfica**

Las imágenes se obtuvieron en los siguientes puntos estratégicos del puente:

a. Superestructura**- Losa de rodadura**

En la figura 60 se puede observar un conjunto de imágenes tomadas durante la inspección aérea y terrestre de la losa de rodadura del Puente Tamborapa. Se ve el uso del dron que se utilizó para registrar todo, junto con imágenes desde arriba y en ángulo, que ayudan a notar el estado de la superficie del tablero.

En la figura 60 puedes ver varias fotos tomadas durante la inspección aérea y terrestre de la losa de rodadura del Puente Tamborapa. Ahí se ve cómo usaron el dron para registrar todo, junto con imágenes desde arriba y en ángulo, que ayudan a notar el estado de la superficie del tablero.

Figura 60*Registro fotográfico de la losa de rodadura del Puente Tamborapa*

Nota. La figura agrupa las imágenes tomadas en campo mediante dron y registro directo, empleadas para el análisis del estado de la losa de rodadura como parte del proceso de documentación fotográfica del puente (2025).

- Barandas y bordes laterales

En la figura 61 se observa el estado actual de las barandas y los bordes del Puente Tamborapa. En algunas zonas del puente se ve pérdida del recubrimiento por lo que las barras de refuerzo quedaron expuestas. En esos puntos, las barras mostraron corrosión, lo que da a conocer que el daño avanza, sobre todo por la humedad y el desgaste natural del entorno.

Además, en varios tramos, el concreto está desprendido y tiene erosión en la superficie, lo que deja pasar el agua directo al acero expuesto. Todo esto quedó registrado durante la inspección en campo y también en las fotos tomadas con el dron.

Figura 61*Fallas en Barandas y bordes laterales del Puente Tamborapa*

Nota. La figura presenta los resultados obtenidos en la evaluación de las barandas y bordes laterales del puente, destacando fallas como corrosión y exposición de barras, registradas durante el proceso de inspección con apoyo de dron (2025).

- Juntas de dilatación

En la figura 62 se ve claramente la zona de las juntas de dilatación del Puente Tamborapa. Resaltan a la vista los desplazamientos entre los elementos. Las juntas presentan una separación irregular; básicamente, las superficies del tablero que ya no están alineadas y se mueven de forma independiente.

Estos desplazamientos son bastante comunes en estructuras que resisten cargas dinámicas constantemente. Por ello, está claro que el puente necesita mantenimiento para asegurar que el tránsito siga siendo fluido y evitar que la superestructura se deteriore aún más.

Figura 62*Fallas en las Juntas de dilatación del Puente Tamborapa*

Nota. La imagen muestra los desplazamientos registrados en las juntas de dilatación del puente, obtenidos mediante inspección aérea con dron (2025).

b. Subestructura

En la figura 63 se ve la subestructura del Puente Tamborapa, donde aparecen las vigas longitudinales, los diafragmas inferiores y las áreas cercanas a los estribos. Mediante el uso del dron, se evidenció que hay eflorescencia en varias superficies expuestas a la humedad constante del río. Esa eflorescencia se muestra como manchas blancas y cristalinas sobre el concreto, sobre todo en zonas donde el agua se filtra o se acumula.

Estos depósitos aparecen en la parte inferior de las vigas, en los diafragmas y en los muros laterales. Eso deja ver que las sales migran desde dentro del concreto hacia la superficie, por la absorción y evaporación continua del agua. En algunos puntos, también se nota humedad persistente, que facilita que este problema se repita de forma constante.

La eflorescencia en la subestructura se debe a la humedad constante del río. Con el tiempo, esto termina dañando la superficie del concreto.

Figura 63

Eflorescencia en vigas, estribos y diafragmas inferiores de la subestructura del Puente Tamborapa.



Nota. Registro obtenido mediante dron, donde se evidencia la presencia de eflorescencia asociada al contacto permanente con humedad en los elementos inferiores del puente.

La Tabla 16 muestra los sectores del Puente Tamborapa que se evaluaron durante la inspección aérea con dron. Se puede observar cuántas imágenes se tomaron de cada parte estructural y un resumen de las observaciones principales: grietas, corrosión, eflorescencia, desplazamientos y barras expuestas. La tabla organiza todo esto para que quede claro qué tanto se cubrió en la inspección y cuáles daños destacan en cada zona.

En total se recopilieron 683 imágenes , distribuidos según la Tabla:

Tabla 16*Registro de imágenes capturadas mediante dron*

Sector evaluado	Nº de imágenes	Observaciones
Losa de rodadura	210	Grietas y humedecimiento
Vigas inferiores	850	Evidencia de corrosión
Estribos	150	Eflorescencia marcada
Juntas / transiciones	40	Posibles desplazamientos
Barandas / bordes	287	Exposición de barras

Nota. El registro fotográfico fue obtenido durante el trabajo de campo mediante el uso de un dron equipado con cámara de alta resolución, lo que permitió capturar imágenes con buena perspectiva y detalle para el análisis estructural.

3.3 Red neuronal convolucional para la identificación automática de fallas en el puente

Tamborapa.

a. VGG16

Este modelo está basado en la arquitectura de VGG16. La información de la imagen se procesó en cinco etapas, donde cada una utiliza pequeñas convoluciones de 3×3 acompañadas de activaciones ReLU, lo que permitió que la red identifique detalles muy simples hasta patrones más complejos. Al final de cada etapa se empleó una capa de MaxPooling, que reduce el tamaño de la imagen y ayuda a que el modelo se vuelva más eficiente sin perder información relevante.

Una vez extraídas estas características, la red utilizó una capa de Adaptive Average Pooling para dejar la salida en un tamaño uniforme, independientemente de la dimensión inicial de la imagen. Con esto, los datos pasaron a una capa totalmente conectada que resume toda la información aprendida y la convierte en cinco valores finales. Estos valores se activaron

mediante una función Sigmoid, adecuada para obtener predicciones independientes en un problema de clasificación con cinco posibles categorías.

En la Tabla 17 se puede ver la estructura exacta de la red neuronal VGG16 que se utilizó para detectar automáticamente fallas en el Puente Tamborapa. Este modelo tiene buena eficiencia porque clasifica imágenes con bastante precisión. La red combina varias capas convolucionales y de pooling, lo que ayuda a sacar las características más relevantes de las imágenes que analizamos.

Gracias a esto, el modelo puede reconocer patrones asociados a distintos tipos de daños. Finalmente, la parte final de la red incluye capas totalmente conectadas que permiten obtener la clasificación de las fallas. Todo el entrenamiento y procesamiento del modelo se realizó en Google Colaboratory para aprovechar sus recursos computacionales.

Tabla 17

Arquitectura de la red neuronal convolucional VGG16 empleada para la identificación automática de fallas del Puente Tamborapa.


Tipo de capa	Parámetros
CONV2D	In: 3 → Out: 64, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 64 → Out: 64, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
MAXPOOL2D	Kernel: 2×2, Stride: 2
CONV2D	In: 64 → Out: 128, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 128 → Out: 128, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
MAXPOOL2D	Kernel: 2×2, Stride: 2
CONV2D	In: 128 → Out: 256, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True

CONV2D	In: 256 → Out: 256, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 256 → Out: 256, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
MAXPOOL2D	Kernel: 2×2, Stride: 2
CONV2D	In: 256 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 512 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 512 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
MAXPOOL2D	Kernel: 2×2, Stride: 2
CONV2D	In: 512 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 512 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
CONV2D	In: 512 → Out: 512, Kernel: 3×3, Stride: 1, Padding: 1
ReLU	inplace = True
MAXPOOL2D	Kernel: 2×2, Stride: 2
ADAPTIVEAVGPOOL2D	Output: 7×7
LINEAR	In: 25088 → Out: 5
SIGMOID	—

Nota. La tabla presenta la arquitectura del modelo VGG16 implementado en el software Google Colaboratory para la clasificación automática de fallas del Puente Tamborapa.

Figura 64

Modelo CNN VGG16 para la clasificación de fallas en el puente Tamborapa.



La figura 65 presenta cómo fue el entrenamiento del modelo VGG16 para identificar fallas en el Puente Tamborapa. Ahí se ven varias épocas , cada una con sus valores de pérdida, precisión y F1-score , tanto en entrenamiento como en validación . A medida que avanza el entrenamiento , el modelo va mejorando su desempeño.

Figura 65

VGG16 empleada para la identificación automática de fallas del Puente Tamborapa

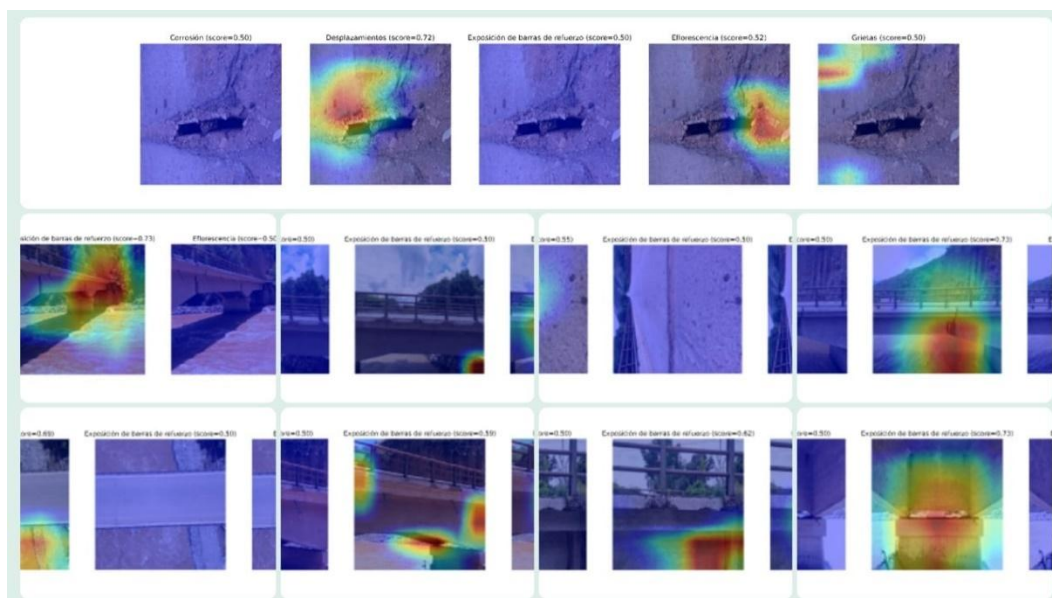
Epoch 18:	Train Loss=0.0886,	Val Loss=0.4669,	Train Acc=0.9652,	Train F1=0.9331,	Val Acc=0.8905,	Val F1=0.7718	
Epoch 19:	Train Loss=0.0779,	Val Loss=0.5050,	Train Acc=0.9711,	Train F1=0.9456,	Val Acc=0.8891,	Val F1=0.7575	
...	Epoch 20:	Train Loss=0.0854,	Val Loss=0.5342,	Train Acc=0.9707,	Train F1=0.9479,	Val Acc=0.8847,	Val F1=0.7602
Epoch 21:	Train Loss=0.0865,	Val Loss=0.5516,	Train Acc=0.9674,	Train F1=0.9375,	Val Acc=0.8832,	Val F1=0.7554	
Epoch 22:	Train Loss=0.0777,	Val Loss=0.5523,	Train Acc=0.9685,	Train F1=0.9401,	Val Acc=0.8730,	Val F1=0.7331	
Epoch 23:	Train Loss=0.0846,	Val Loss=0.4179,	Train Acc=0.9696,	Train F1=0.9386,	Val Acc=0.8847,	Val F1=0.7740	
Epoch 24:	Train Loss=0.0669,	Val Loss=0.4823,	Train Acc=0.9729,	Train F1=0.9501,	Val Acc=0.8818,	Val F1=0.7414	
Epoch 25:	Train Loss=0.0786,	Val Loss=0.5870,	Train Acc=0.9703,	Train F1=0.9418,	Val Acc=0.8788,	Val F1=0.7448	
Epoch 26:	Train Loss=0.0702,	Val Loss=0.5202,	Train Acc=0.9714,	Train F1=0.9411,	Val Acc=0.8905,	Val F1=0.7709	
Epoch 27:	Train Loss=0.0718,	Val Loss=0.4518,	Train Acc=0.9703,	Train F1=0.9441,	Val Acc=0.8803,	Val F1=0.7677	
Epoch 28:	Train Loss=0.0684,	Val Loss=0.4780,	Train Acc=0.9725,	Train F1=0.9456,	Val Acc=0.8920,	Val F1=0.7783	
Epoch 29:	Train Loss=0.0661,	Val Loss=0.5440,	Train Acc=0.9747,	Train F1=0.9495,	Val Acc=0.8788,	Val F1=0.7591	
Epoch 30:	Train Loss=0.0662,	Val Loss=0.5355,	Train Acc=0.9740,	Train F1=0.9485,	Val Acc=0.8803,	Val F1=0.7816	
Epoch 31:	Train Loss=0.0606,	Val Loss=0.6555,	Train Acc=0.9736,	Train F1=0.9510,	Val Acc=0.8905,	Val F1=0.7652	
Epoch 32:	Train Loss=0.0625,	Val Loss=0.4397,	Train Acc=0.9747,	Train F1=0.9530,	Val Acc=0.8949,	Val F1=0.7743	
Epoch 33:	Train Loss=0.0647,	Val Loss=0.6262,	Train Acc=0.9751,	Train F1=0.9534,	Val Acc=0.8861,	Val F1=0.7523	
Epoch 34:	Train Loss=0.0618,	Val Loss=0.4970,	Train Acc=0.9740,	Train F1=0.9483,	Val Acc=0.8861,	Val F1=0.7766	
Epoch 35:	Train Loss=0.0595,	Val Loss=0.8462,	Train Acc=0.9729,	Train F1=0.9466,	Val Acc=0.8832,	Val F1=0.7450	
Epoch 36:	Train Loss=0.0509,	Val Loss=0.5437,	Train Acc=0.9784,	Train F1=0.9565,	Val Acc=0.8818,	Val F1=0.7387	
Epoch 37:	Train Loss=0.0576,	Val Loss=0.5368,	Train Acc=0.9780,	Train F1=0.9576,	Val Acc=0.8905,	Val F1=0.7559	
Epoch 38:	Train Loss=0.0565,	Val Loss=0.5387,	Train Acc=0.9722,	Train F1=0.9468,	Val Acc=0.8861,	Val F1=0.7501	
Epoch 39:	Train Loss=0.0560,	Val Loss=0.6520,	Train Acc=0.9780,	Train F1=0.9557,	Val Acc=0.8905,	Val F1=0.7908	
Epoch 40:	Train Loss=0.0544,	Val Loss=0.4894,	Train Acc=0.9744,	Train F1=0.9504,	Val Acc=0.8832,	Val F1=0.7496	
Epoch 41:	Train Loss=0.0509,	Val Loss=0.4631,	Train Acc=0.9773,	Train F1=0.9553,	Val Acc=0.8861,	Val F1=0.7747	
Epoch 42:	Train Loss=0.0607,	Val Loss=0.6715,	Train Acc=0.9725,	Train F1=0.9463,	Val Acc=0.8861,	Val F1=0.7703	
Epoch 43:	Train Loss=0.0532,	Val Loss=0.4331,	Train Acc=0.9769,	Train F1=0.9549,	Val Acc=0.8964,	Val F1=0.7527	
Epoch 44:	Train Loss=0.0542,	Val Loss=0.6904,	Train Acc=0.9740,	Train F1=0.9499,	Val Acc=0.8978,	Val F1=0.7702	
Epoch 45:	Train Loss=0.0566,	Val Loss=0.5201,	Train Acc=0.9773,	Train F1=0.9544,	Val Acc=0.8905,	Val F1=0.7494	
Epoch 46:	Train Loss=0.0539,	Val Loss=0.5253,	Train Acc=0.9769,	Train F1=0.9560,	Val Acc=0.8876,	Val F1=0.7540	

b. MobileNet

La figura 66 muestra cómo se organizó el modelo, iniciando con una capa inicial que toma la imagen y genera las primeras características con 32 canales. Esta parte actúa como la base del proceso, ya que permitió que el sistema identifique patrones simples. A continuación, se realizó con varios bloques llamados Inverted Residual, que trabajan expandiendo los canales, procesando la información y volviéndola a reducir. Este mecanismo ayuda a manejar los datos de forma eficiente sin aumentar demasiado la complejidad del sistema.

Figura 66

Modelo CNN MobileNet para la clasificación de fallas en el puente Tamborapa.



A medida que se avanza por los bloques, el número de canales va aumentando de manera gradual (16, 24, 32, 64, 96 y 160), lo que permite que el modelo capture información más detallada. Algunos de estos bloques también reducen el tamaño de la imagen para quedarse solo con lo más importante. Al final, una convolución amplía la información hasta 1280 canales y, con esa representación final, se pasa a una capa lineal que entrega cinco valores. Estos valores se procesan con una función Sigmoid, lo que permite interpretar el resultado como probabilidades para cada una de las categorías que se desean clasificar.

Tabla 18

Arquitectura del modelo MobileNet empleada para la identificación automática de fallas del Puente Tamborapa

Tipo de Bloque/Capa	In Channels	Out Channels	Kernel Size	Stride	Notas / Activación
Conv2dNormActivation	3	32	(3, 3)	(2, 2)	ReLU6 – Capa inicial
InvertedResidual	32	16	(1, 1) - (3, 3)	(1, 1)	PW + DW, proyección
InvertedResidual	16	24	(1, 1) - (3, 3)	(2, 2)	Expansión 16 → 96
InvertedResidual	24	24	(1, 1) - (3, 3)	(1, 1)	Expansión 24 → 144
InvertedResidual	24	32	(1, 1) - (3, 3)	(2, 2)	Expansión 24 → 144
InvertedResidual	32	32	(1, 1) - (3, 3)	(1, 1)	Expansión 32 → 192
InvertedResidual	32	32	(1, 1) - (3, 3)	(1, 1)	Repetición
InvertedResidual	32	64	(1, 1) - (3, 3)	(2, 2)	Expansión 32 → 192
InvertedResidual	64	64	(1, 1) - (3, 3)	(1, 1)	Expansión 64 → 384
InvertedResidual	64	64	(1, 1) - (3, 3)	(1, 1)	Repetición
InvertedResidual	64	64	(1, 1) - (3, 3)	(1, 1)	Repetición
InvertedResidual	64	96	(1, 1) - (3, 3)	(1, 1)	Expansión 64 → 384
InvertedResidual	96	96	(1, 1) - (3, 3)	(1, 1)	Expansión 96 → 576
InvertedResidual	96	96	(1, 1) - (3, 3)	(1, 1)	Repetición

InvertedResidual	96	160	(1, 1) - (3, 3)	(2, 2)	Expansión 96 → 576
InvertedResidual	160	160	(1, 1) - (3, 3)	(1, 1)	Expansión 160 → 960
InvertedResidual	160	160	(1, 1) - (3, 3)	(1, 1)	Repetición
InvertedResidual	160	320	(1, 1) - (3, 3)	(1, 1)	Expansión 160 → 960
Conv2dNormActivation	320	1280	(1, 1)	(1, 1)	ReLU6 – Capa final
Linear + Sigmoid	1280	5	–	–	Clasificador final

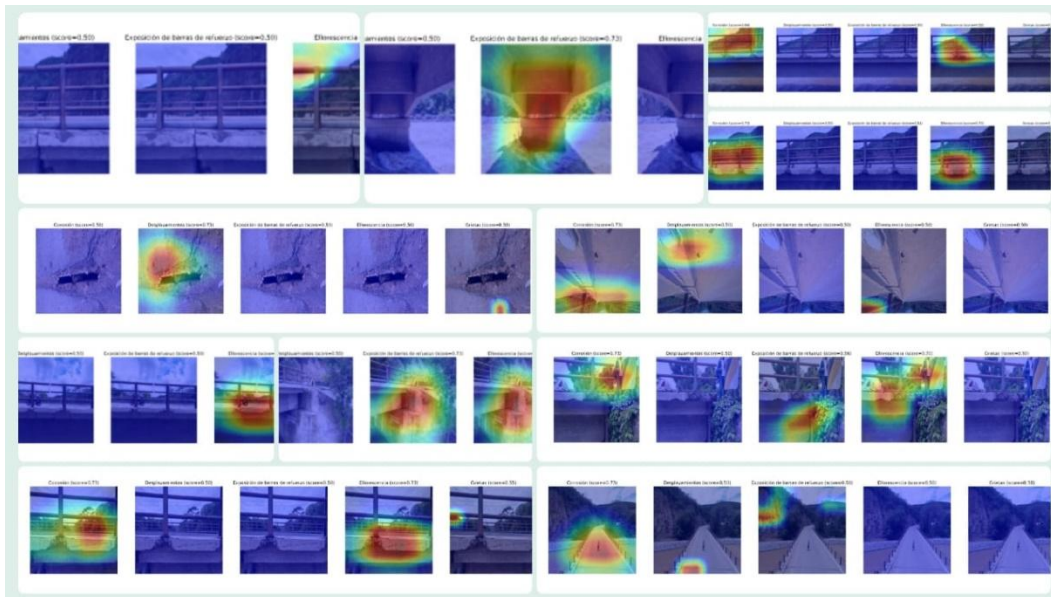
c. Dese Net121

En este modelo se presentan los resultados del modelo DenseNet adaptado para clasificación en cinco categorías. El procesamiento inicio con una capa convolucional inicial que transforma las imágenes de 3 canales en 64 mapas de características, seguida de normalización y activación ReLU para estabilizar y activar la información. La capa del MaxPooling reducio la resolución espacial, preparando los datos para los bloques densos.

La figura 67 muestra un conjunto de mapas de calor generados mediante Grad-CAM sobre imágenes reales de elementos de concreto, correspondientes a diferentes categorías de daño. Los mapas resaltan las regiones que el modelo DenseNet121 consideró más relevantes para emitir cada predicción, evidenciando un enfoque adecuado hacia zonas deterioradas como grietas, corrosión, eflorescencias y desplazamientos.

Figura 67

Modelo CNN DenseNet121 para la clasificación de fallas en el puente Tamborapa.



El modelo tiene cuatro bloques densos. En cada uno, las capas se conectan entre sí, lo que ayuda a aprovechar mejor la información y a que el aprendizaje sea más eficiente. Entre estos bloques se incluyó capas de transición, que reducen la cantidad de canales y la resolución espacial para mantener el modelo manejable. Los bloques densos incremento progresivamente el número de canales: de 128 en la primera transición, hasta 1024 en los bloques finales, capturando patrones cada vez más complejos. Al final, una capa de normalización y un clasificador lineal con función Sigmoid dan cinco valores de salida: cada uno muestra la probabilidad de que la imagen pertenezca a una de las cinco clases. lo que garantiza que es un modelo profundo, eficiente y con una estructura que le permite extraer representaciones complejas de forma clara y ordenada..

Tabla 19

Arquitectura del modelo DenseNet121 empleada para la identificación automática de fallas del Puente Tamborapa

Capa/Componente	Tipo	Parámetros / Configuración	Notas
features.conv0	Conv2d	in=3, out=64, kernel=(7,7), stride=2, padding=3, bias=False	Capa convolucional inicial
features.norm0	BatchNorm2d	num_features=64, eps=1e-05, momentum=0.1	Normalización por lotes
features.relu0	ReLU	inplace=True	Activación ReLU
features.pool0	MaxPool2d	kernel_size=3, stride=2, padding=1	Reducción espacial
features.denseblock1	_DenseBlock	6 capas densas (denselayer1-6)	Cada capa: BN → ReLU → Conv(1x1) → BN → ReLU → Conv(3x3)
features.transition1	_Transition	norm: BN(256), conv: Conv2d(256→128, 1×1), pool: AvgPool2d(2,2)	Transición entre bloques, reduce canales y resolución
features.denseblock2	_DenseBlock	12 capas densas (denselayer1-12)	Misma estructura que denseblock1
features.transition2	_Transition	norm: BN(512), conv: Conv2d(512→256, 1×1), pool: AvgPool2d(2,2)	Segunda transición
features.denseblock3	_DenseBlock	24 capas densas (denselayer1-24)	Bloque denso más profundo
features.transition3	_Transition	norm: BN(1024), conv: Conv2d(1024→512, 1×1), pool: AvgPool2d(2,2)	Tercera transición
features.denseblock4	_DenseBlock	16 capas densas (denselayer1-16)	Bloque denso final
features.norm5	BatchNorm2d	num_features=1024, eps=1e-05, momentum=0.1	Normalización final antes de clasificar

Nota. La tabla presenta la arquitectura del modelo DenseNet121 implementado en Google Colaboratory para el proceso de clasificación automática de fallas en el Puente Tamborapa.

d. YOLO

El modelo YOLO tiene una arquitectura orientada a la detección de objetos trabajando en varias escalas. Su procesamiento inicia con capas convolucionales que incrementan de forma gradual la cantidad de canales a la vez que reducen la resolución de la imagen. A lo largo del recorrido se integran bloques C3k2, cuyo propósito es reforzar la extracción de rasgos mediante conexiones internas y mecanismos residuales que optimizan el flujo de información.

Más adelante, los módulos SPPF y C2PSA aportan un mayor alcance espacial y permiten que la red centre su atención en las características más importantes. En la etapa de decodificación, se usan operaciones de upsampling y se mezclan datos de diferentes escalas por medio de concatenaciones. Después, vuelven a entrar los bloques C3k2 para depurar esas representaciones. Al final, el módulo Detect toma las características de los mapas de 64, 128 y 256 canales y, con eso, genera las predicciones para cinco clases. Como resultado se obtiene una arquitectura muy eficiente, que logra detectar objetos de distintos tamaños con buen nivel de detalle.

Tabla 20

Arquitectura del modelo YOLO optimizado para la detección multiclase en imágenes

Módulo	Parámetros	Argumentos
Conv	464	[3, 16, 3, 2]
Conv	4672	[16, 32, 3, 2]
C3k2	6640	[32, 64, 1, False, 0.25]
Conv	36992	[64, 64, 3, 2]
C3k2	26080	[64, 128, 1, False, 0.25]
Conv	147712	[128, 128, 3, 2]
C3k2	87040	[128, 128, 1, True]
Conv	295424	[128, 256, 3, 2]

2

2 2

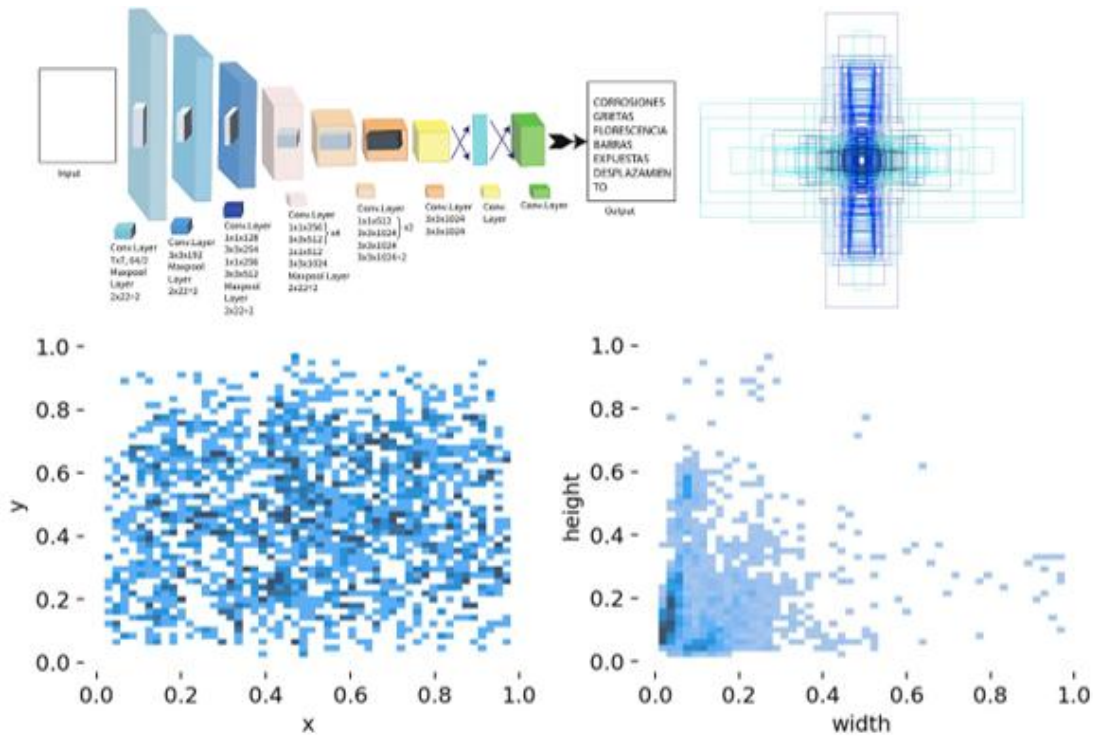
C3k2	346112	[256, 256, 1, True]
SPPF	164608	[256, 256, 5]
C2PSA	249728	[256, 256, 1]
Upsample	0	[None, 2, "nearest"]
Concat	0	[1]
C3k2	111296	[384, 128, 1, False]
Upsample	0	[None, 2, "nearest"]
Concat	0	[1]
C3k2	32096	[256, 64, 1, False]
Conv	36992	[64, 64, 3, 2]
Concat	0	[1]
C3k2	86720	[192, 128, 1, False]
Conv	147712	[128, 128, 3, 2]
Concat	0	[1]
C3k2	378880	[384, 256, 1, True]
Detect	431647	[5, [64, 128, 256]]

Nota: La tabla detalla cada módulo de la arquitectura, indicando el número de parámetros y los argumentos utilizados en cada operación. (2025)

En la figura 68 se puede ver cómo funciona todo el sistema basado en redes neuronales convolucionales (CNN) usando el modelo YOLO para detectar y clasificar daños en el Puente Tamborapa. Todo inicia con la base de datos, donde se separan los datos en conjuntos de entrenamiento, validación y prueba. Después, viene la parte de crear, ajustar y validar el modelo. Al final, el sistema reconoce automáticamente patrones y detecta fallas como corrosión, grietas, eflorescencia, barras expuestas y desplazamientos.

Figura 68

Arquitectura y flujo de procesamiento del modelo YOLO para la estimación de daños en el Puente Tamborapa.

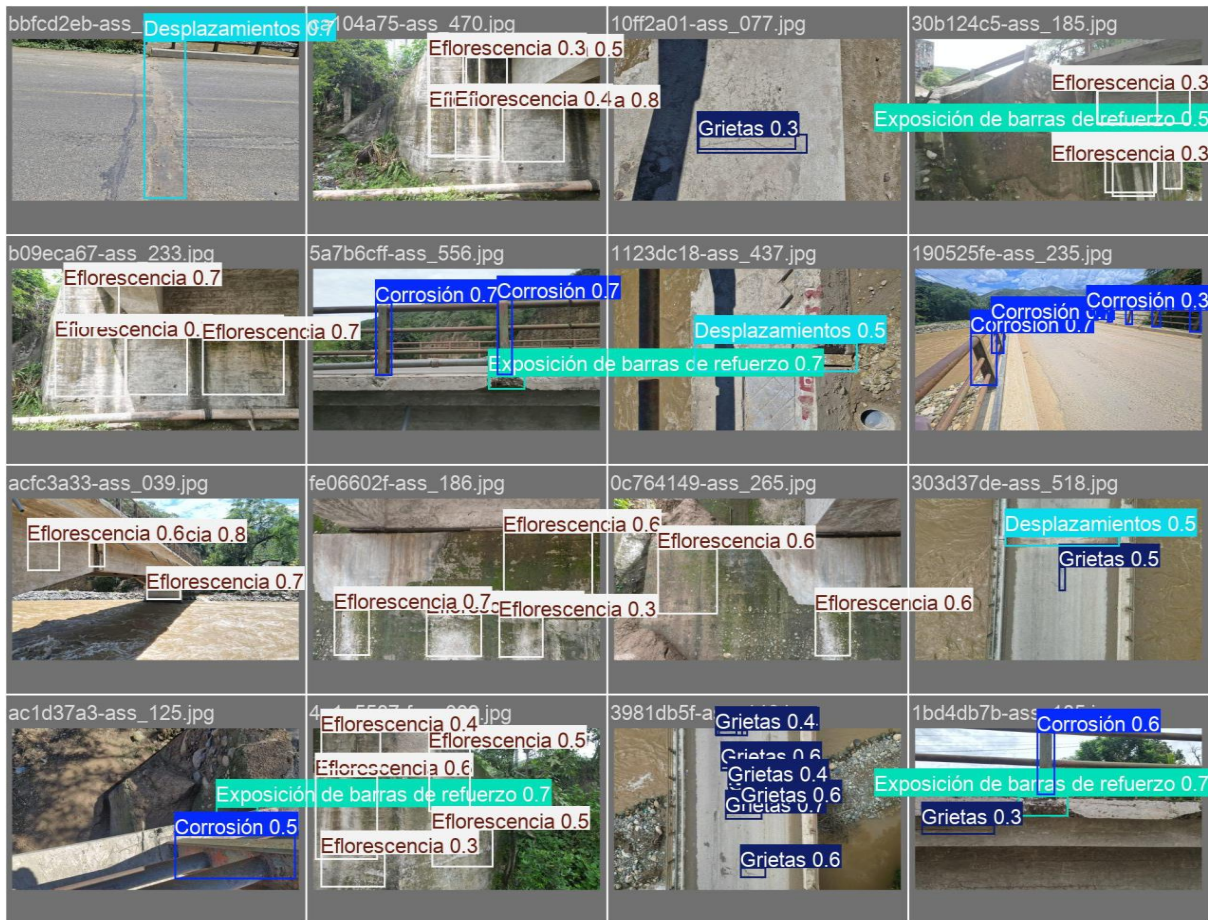


Nota. La figura representa la arquitectura y el flujo de trabajo del modelo YOLO empleado para la detección automática de daños en elementos de concreto del Puente Tamborapa. (Elaboración propia).

La figura 69 muestra algunos resultados del modelo YOLO en la detección automática de daños usando imágenes del Puente Tamborapa. En cada imagen aparecen cuadros que marcan las zonas donde el modelo detectó fallas, junto con sus etiquetas y niveles de confianza. Se identifican problemas como eflorescencia, corrosión, grietas, exposición de barras de refuerzo y desplazamientos. Todo esto demuestra que el modelo puede ubicar y clasificar varios tipos de daños en superficies de concreto.

Figura 69

Resultados de detección de daños mediante YOLO en elementos del Puente Tamborapa



Nota. Resultados de la detección automática de daños mediante el modelo YOLO, mostrando la localización y clasificación de patologías en el Puente Tamborapa. Elaboración propia.

3.3.1 Comparación De Las CNN

La tabla muestra la comparación del desempeño de cuatro arquitecturas de redes neuronales convolucionales (CNN) empleadas para la detección de daños en el Puente Tamborapa, utilizando las métricas de **loss**, **accuracy (precisión)** y **F1-score**, evidenciando que el modelo **YOLO** presenta el mejor rendimiento general.

Tabla 21

Comparación del desempeño de las redes neuronales convolucionales (CNN) para la detección de daños

Tipo de red	Loss	Accuracy (Precisión) (%)	F1-score (%)
-------------	------	--------------------------	--------------

VGG16	0.975	90.0	82.0
MobileNet	0.975	95.0	82.5
DenseNet121	0.975	92.0	82.5
YOLO	0.980	96.0	96.0

Nota. Los valores corresponden al rendimiento de los modelos CNN entrenados con el conjunto de datos del Puente Tamborapa. Elaboración propia.

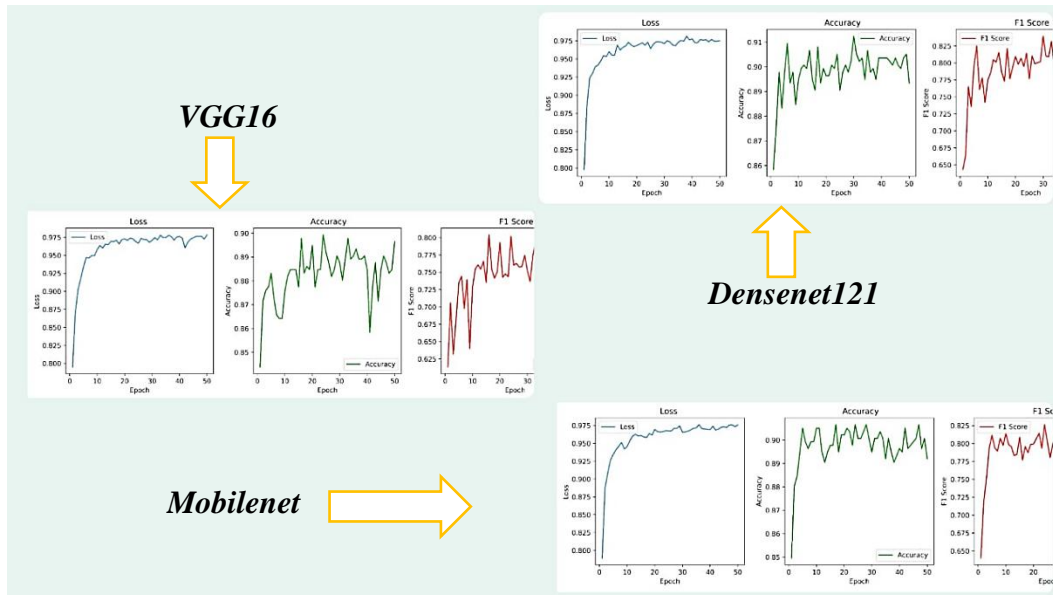
3.4 Validar La Red Neuronal Convolutacional.

Después del entrenamiento de los modelos para la clasificación de daños en el puente Tamborapa se llevó la validación correspondiente adecuada de cada uno de los modelos. La validación se desarrolló comparando predicciones del modelo con datos reales, utilizando métricas recomendadas en clasificación y detección de fallas en el Puente Tamborapa.

La figura 70 integra las curvas de pérdida (Loss), exactitud (Accuracy) y F1-Score correspondientes a los modelos VGG16, MobileNet y DenseNet121, permitiendo una visualización comparativa de su comportamiento durante las 50 épocas de entrenamiento. En el conjunto de gráficos se observa que DenseNet121 presenta la mayor estabilidad en las tres métricas, con fluctuaciones mínimas y un rendimiento uniforme. MobileNet muestra un comportamiento equilibrado, con convergencia estable y variabilidad moderada, lo que confirma su eficiencia en bases de datos reducidas. Por su parte, VGG16 exhibe mayor dispersión en las métricas, especialmente en Accuracy y F1-Score, reflejando una sensibilidad más pronunciada a la variabilidad del conjunto de validación. Esta imagen general facilita la comparación integral del desempeño de los modelos y respalda la selección de DenseNet121 como el modelo más consistente y robusto para la identificación automática de fallas .

Figura 70

Resultados de las curvas validación de las redes neuronales convolucionales



Nota. La imagen integra las métricas de validación de los tres modelos convolucionales evaluados para la clasificación multietiqueta de fallas en el Puente Tamborapa.

3.4.1 Resultados de validación

Los resultados demuestran que la red neuronal posee una capacidad adecuada para identificar daños, lo cual facilita la toma de decisiones preventivas con resultados de cada una de las redes.

La tabla 22 presenta los valores finales obtenidos durante la etapa de validación del mejor modelo evaluado para la identificación automática de fallas en el Puente Tamborapa. Se incluyen métricas de clasificación multietiqueta (Accuracy, Precision, Recall y F1-score), así como el indicador mAP@50 correspondiente al modelo YOLO empleado para la detección de objetos, lo que permite comparar de manera integral el rendimiento global del sistema de reconocimiento. Los valores muestran que el modelo alcanzó un desempeño robusto y consistente en todas las métricas evaluadas, destacando su alta capacidad para identificar correctamente cada tipo de daño estructural.

Tabla 22*Desempeño final del mejor modelo de red neuronal convolucional*

Métrica	Valor obtenido de cada red Neuronal convolucional.
Accuracy	0.961
Precision	0.96
Recall	0.96
F1-score	0.96
mAP@50 (YOLO)	0.96


Nota. Los valores reportados corresponden a los resultados finales obtenidos después de la validación del modelo con el conjunto de prueba. (2025)

a. Validación del modelo VGG16

La figura 71 muestra el comportamiento de las métricas de validación del modelo VGG16 durante 50 épocas de entrenamiento. En la gráfica de pérdida (Loss) se observa una disminución inicial seguida de fluctuaciones moderadas, lo que evidencia cierta sensibilidad del modelo a la variabilidad del conjunto de datos. La curva de exactitud (Accuracy) presenta picos cercanos al 0.91, aunque con variaciones pronunciadas entre épocas. El comportamiento del F1-Score refleja una estabilización progresiva, con valores entre 0.75 y 0.82, lo que indica un desempeño adecuado, pero menos consistente frente a los otros modelos comparados.

Figura 71

Curvas de validación del modelo VGG16: Loss, Accuracy y F1-Score




Nota. Las métricas corresponden al proceso de validación del modelo VGG16 configurado para clasificación multietiqueta de fallas . (2025)

b. Validación del modelo MobileNet

La figura 72 presenta la evolución de las métricas de validación del modelo MobileNet durante el entrenamiento. La pérdida (Loss) muestra una convergencia estable y uniforme, con menor variabilidad que VGG16. La exactitud (Accuracy) mantiene valores cercanos a 0.90 con oscilaciones reducidas, lo que evidencia una buena generalización pese al menor tamaño de la base de datos. En cuanto al F1-Score, el modelo conserva valores entre 0.78 y 0.83, lo cual refleja un desempeño confiable y equilibrado, característico de las arquitecturas optimizadas para eficiencia computacional.

Figura 72

Curvas de validación del modelo MobileNet: Loss, Accuracy y F1-Score




Nota. Las métricas corresponden al proceso de validación del modelo MobileNet adaptado para clasificación multietiqueta. (2025)

c. Validación del modelo DenseNet121

La figura 73 muestra el comportamiento de las métricas de validación del modelo DenseNet121, el cual presenta la mayor estabilidad entre las arquitecturas evaluadas. La pérdida (Loss) disminuye de forma consistente y con mínima fluctuación a través de las épocas. La exactitud (Accuracy) se mantiene estable alrededor de 0.90, con menor dispersión que VGG16 y MobileNet. El F1-Score presenta los valores más robustos del conjunto, oscilando entre 0.80 y 0.83 con notable uniformidad, lo que refleja la capacidad del modelo para capturar patrones complejos asociados a fallas como corrosión y eflorescencia.

Figura 73

Curvas de validación del modelo DenseNet121: Loss, Accuracy y F1-Score



Nota. Las métricas corresponden al proceso de validación del modelo DenseNet121 configurado para clasificación multietiqueta. (2025)

d. Validación del modelo YOLO

La tabla 23 presenta los resultados obtenidos durante la validación del modelo YOLO aplicado a la detección de fallas en el Puente Tamborapa. Se incluyen métricas fundamentales como Precisión (P), Recall (R), mAP50 y mAP50-95, evaluadas para cada una de las cinco clases de daño: corrosión, desplazamientos, eflorescencia, exposición de barras de refuerzo y

grietas. Los valores muestran un rendimiento sobresaliente en clases como exposición de barras de refuerzo y corrosión, donde el modelo alcanza altos niveles de precisión y recall, reflejando una detección eficiente y consistente. En contraste, las métricas correspondientes a eflorescencia y grietas presentan valores menores, lo cual evidencia que estas clases poseen mayor complejidad visual y variabilidad en sus patrones, dificultando su reconocimiento automático. La fila general ("todas") resume el desempeño global del modelo, destacando un mAP50 de 0.639 y un mAP50-95 de 0.301, valores que confirman que YOLO ofrece resultados adecuados para la identificación multiclase, especialmente en objetos pequeños y defectos localizados.

Tabla 23

Resultados de validación del modelo YOLO para la detección de fallas

Clase	Imágenes	Instancias	Precisión (P)	Recall (R)	mAP50	mAP50-95
Todas (all)	137	486	0.677	0.636	0.639	0.301
Corrosión	74	211	0.723	0.892	0.809	0.463
Desplazamientos	17	21	0.745	0.619	0.673	0.353
Eflorescencia	40	90	0.437	0.422	0.435	0.168
Exposición de barras de refuerzo	43	77	0.837	0.896	0.872	0.407
Grietas	33	87	0.642	0.350	0.406	0.115

Nota. Los valores reportados corresponden a la validación realizada con 137 imágenes y 486 instancias de fallas . (2025)


La figura 74 presenta la matriz de confusión normalizada correspondiente al modelo YOLO, evidenciando su desempeño en la identificación de las distintas patologías evaluadas: corrosión, desplazamientos, eflorescencia, exposición de barras de refuerzo, grietas y fondo (background). Se observa una alta precisión en clases como exposición de barras de refuerzo (1.00) y corrosión (0.97), mientras que clases como eflorescencia muestran mayores

21

confusiones respecto al fondo, indicando un desafío en la diferenciación visual de estas características superficiales.

Figura 74

Matriz de confusión normalizada del modelo YOLO para la detección de patologías en estructuras de concreto.




Nota. La matriz muestra el desempeño del modelo en cada clase evaluada, indicando el porcentaje de aciertos y las confusiones entre categorías durante el proceso de detección.

La figura 75 presenta la evolución de las funciones de pérdida y métricas de evaluación del modelo YOLO a lo largo de las épocas de entrenamiento. Se muestran las pérdidas asociadas al cálculo del cuadro delimitador (box_loss), clasificación (cls_loss) y distribución (dfl_loss), tanto en entrenamiento como validación, junto con el comportamiento progresivo de precisión, recall y mAP en sus variantes mAP50 y mAP50-95. En general, se observa una disminución sostenida de las pérdidas y un incremento gradual de las métricas, evidenciando un proceso de aprendizaje estable y con mejoras consistentes en la detección.

Figura 75

Comportamiento de las funciones de pérdida y métricas de desempeño durante el entrenamiento del modelo YOLO.

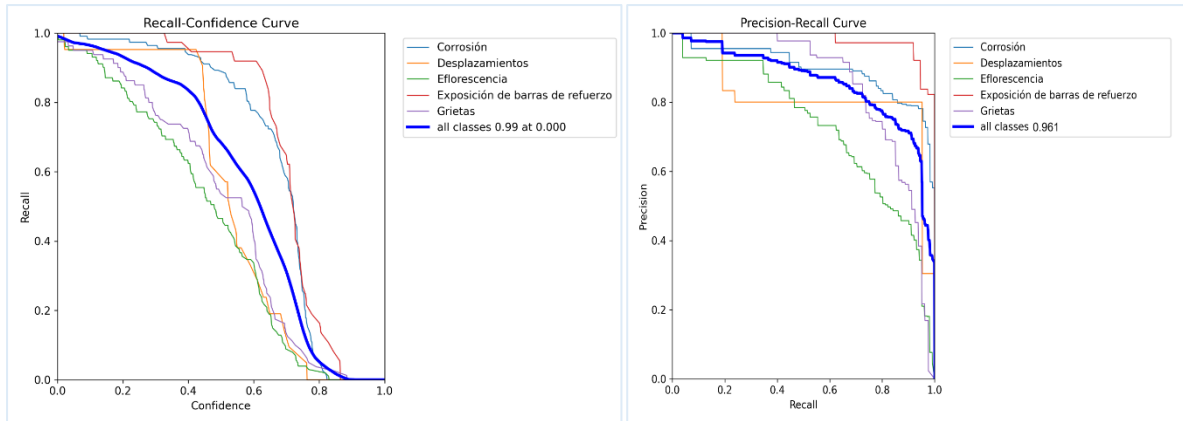


Nota. Las gráficas muestran la reducción de las funciones de pérdida y el incremento de las métricas de evaluación, reflejando la mejora del desempeño del modelo YOLO durante el entrenamiento.

En las figuras 76 y 77 las gráficas presentan las métricas de rendimiento del modelo YOLO en relación con el nivel de confianza aplicado durante la detección. Se muestran las curvas Precisión–Confianza, F1–Confianza, Recall–Confianza y Precisión–Recall para cada clase evaluada: corrosión, desplazamientos, eflorescencia, exposición de barras de refuerzo y grietas. Se observa una tendencia ascendente en precisión a medida que aumenta el umbral de confianza, mientras que el recall decrece de forma proporcional, evidenciando el compromiso entre detección exhaustiva y precisión selectiva. La curva Precisión–Recall indica un comportamiento general robusto del modelo, reflejando una capacidad adecuada para identificar daños en diversos escenarios y condiciones visuales.

Figura 76

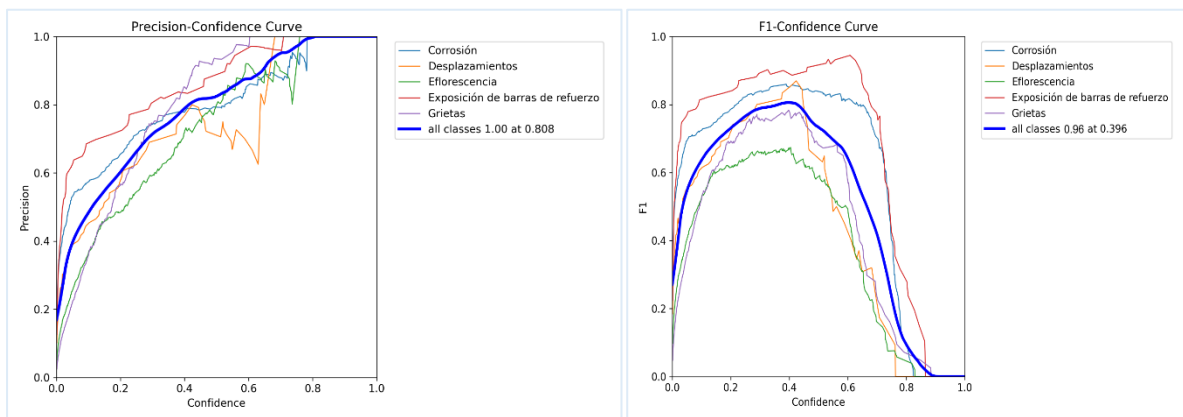
Curvas Precision–Confidence del modelo YOLO.



Nota. La imagen presenta la relación entre la confianza del modelo y su precisión y F1-Score, mostrando el comportamiento del rendimiento al aumentar el umbral de detección.

Figura 77

Curvas Precision–Confidence y F1–Confidence del modelo YOLO



Nota. Las curvas reflejan la variación del recall y la relación precisión-recuperación, evidenciando el equilibrio entre aciertos y omisiones en la detección según el nivel de confianza.

IV. DISCUSIÓN:

Los daños identificados como corrosión, grietas, eflorescencia, barras expuestas y desplazamientos coinciden con los tipos de fallas comúnmente reportadas en puentes de concreto, y la presencia significativa de corrosión del acero de refuerzo y exposición de barras en vigas, bordes del tablero y barandas es similar a lo descrito por Dorafshan et al. (2018), quienes señalan que los elementos metálicos en zonas vulnerables al contacto con humedad suelen registrar deterioros acelerados en ambientes de alta humedad relativa. Asimismo, Zoubir et al. (2022) describen que la pérdida del recubrimiento y la corrosión activa son patologías frecuentes en puentes con mantenimiento limitado y con exposición constante a agentes como sales, cloruros y variaciones térmicas, condiciones también presentes en el Puente Tamborapa. La eflorescencia, hallada en los estribos y zonas con filtración, constituye otro deterioro recurrente en estructuras emplazadas en contextos fluviales. Este comportamiento coincide con Cao et al. (2023), quienes señalan que la migración de sales hacia la superficie está directamente vinculada a procesos de humedecimiento, propios de estructuras en contacto con corrientes de agua. En este sentido, la presencia de eflorescencia en el Puente Tamborapa confirma la influencia del entorno hídrico en la degradación progresiva del concreto. En cuanto a las grietas longitudinales y transversales registradas en la losa de rodadura y la cara inferior de las vigas, su distribución y orientación sugieren efectos de fatiga, retracción del concreto y posible deficiencia en el drenaje, hallazgos similares descritos por Jin et al. (2023) y Dorafshan et al. (2018) quienes sostienen que las grietas en puentes de concreto suelen estar asociadas tanto a cargas cíclicas como a procesos de degradación ambiental, aspectos que se observaron también en el Puente Tamborapa. Finalmente, los desplazamientos registrados en apoyos y juntas evidencian un inicio de pérdida de alineación, coincidiendo con lo reportado por Osco et al. (2021), estos autores destacan que en puentes sometidos a cargas variables, vibraciones y ausencia de mantenimiento periódico, suelen aparecer deformaciones tempranas en las zonas

de apoyo. Asimismo, la frecuencia de daños registrada en el Puente Tamborapa muestra que la corrosión representa aproximadamente el 43 % de todos los casos identificados, seguida por la eflorescencia (19.1 %), las grietas (18.7 %), la exposición de barras (14.4 %) y los desplazamientos (4.8 %). Esta distribución porcentual coincide con las tendencias reportadas por Abdelkader et al. (2023), quienes, en un análisis global de patologías en puentes de concreto, señalan que la corrosión constituye alrededor del 19.33 % de los defectos reportados, mientras que las grietas y fisuras alcanzan valores cercanos al 28.26 %, ubicándose entre las manifestaciones con mayor predominio. Aunque los porcentajes obtenidos en el Puente Tamborapa son superiores, especialmente en relación con la corrosión.

En la recolección y sistematización de 683 imágenes de la superestructura y subestructura del Puente Tamborapa mediante el uso de un dron, permitieron contar con un registro visual eficiente de las principales fallas presentes en la en él puente. La captura aérea realizada con el dron DJI Mini 3 Pro proporcionó imágenes de alta resolución de 4032×2268 píxeles, permitiendo identificar daños en zonas que no son accesibles mediante inspección terrestre, especialmente en vigas, diafragmas, juntas de dilatación y caras laterales del tablero. El uso de drones para inspecciones coincide con lo señalado por Aldana-Rodríguez et al. (2021), quienes destacan que las aeronaves no tripuladas permiten obtener registros detallados en elementos ubicados en zonas de difícil acceso, incrementando la precisión y cobertura del diagnóstico. Asimismo, la documentación de daños como corrosión, fisuras, eflorescencia y exposición de barras en barandas y bordes laterales concuerda con los hallazgos de Zoubir et al. (2022) quienes señalan que los drones son útiles para registrar pérdida de recubrimiento y deterioro superficial en elementos sometidos a la acción de humedad y agentes ambientales agresivos. Osco et al. (2021), comprobaron mediante fotogrametría desde dron que las juntas y apoyos presentan deformaciones diferenciales cuando están sometidos a vibraciones

constantes y ciclos térmicos. Los desplazamientos identificados en Tamborapa se alinean con estos mecanismos de deterioro típicos. Las imágenes capturadas con el dron en 4032×2268 píxeles proporcionaron la resolución necesaria para identificar detalles finos como grietas delgadas, corrosión localizada y desprendimientos de recubrimiento, alcanzando un nivel de nitidez comparable al reportado por Taboada (2022), quien empleó cámaras de 4000×3000 píxeles en inspecciones fotogramétricas con dron, demostrando que resoluciones superiores a los 12 MP permiten registrar con precisión daños superficiales en estructuras. Esta similitud confirma que la resolución utilizada en el Puente Tamborapa cumple con los estándares necesarios para una detección confiable de patologías.

Los modelos de redes neuronales convolucionales (VGG16, MobileNet, DenseNet121 y YOLO) para la identificación automática de fallas en el Puente Tamborapa, permitieron evaluar el desempeño de distintas arquitecturas. Cada modelo fue ajustado para clasificar cinco tipos de fallas : corrosión, grietas, eflorescencia, barras expuestas y desplazamientos. El modelo **VGG16**, adaptado mediante la incorporación de capas de *Adaptive Average Pooling* y funciones de activación Sigmoid para clasificación multietiqueta, mostró una adecuada capacidad para extraer rasgos jerárquicos desde patrones simples hasta estructuras de daño más complejas. Estos resultados coinciden con Simonyan & Zisserman (2015), quienes demostraron que la simplicidad de las convoluciones 3×3 y el uso sistemático de *MaxPooling* permiten obtener características eficientes en tareas de reconocimiento. Asimismo, Dorafshan et al. (2018) evidenciaron, que arquitecturas basadas en VGG son eficaces en la identificación de grietas y defectos en puentes, particularmente cuando se emplean imágenes aéreas o capturas de alta resolución como las utilizadas en este estudio. El modelo MobileNet, se caracterizó por sus bloques *Inverted Residual* y convoluciones separables en profundidad, presentó un desempeño eficiente para el procesamiento de los 683 registros obtenidos, manteniendo bajo costo computacional y buena generalización. Estos resultados son similares

con Howard et al. (2017), quienes destacan que MobileNet es especialmente adecuado para aplicaciones de inspección estructural en campo debido a su ligereza y eficacia en escenarios con recursos limitados. Hui et al. (2025) demostraron que MobileNet puede identificar grietas superficiales y corrosión con alta precisión cuando se entrena con bases de datos amplias, lo que respalda su uso en la investigación. El modelo DenseNet121, presenta conexiones directas entre todas las capas dentro de cada bloque denso, mostrando una capacidad destacada para capturar patrones complejos asociados a daños como eflorescencia y corrosión. La eficiencia en la reutilización de características observada durante su entrenamiento coincide con Huang et al. (2017), quienes demostraron que DenseNet reduce la redundancia y mejora el flujo de gradientes, incrementando la capacidad del modelo para aprender detalles finos. Kao et al. (2023) reportaron que DenseNet supera a arquitecturas tradicionales en tareas de clasificación de fallas en infraestructura, especialmente cuando se requiere alta sensibilidad a texturas irregulares y variaciones sutiles en la superficie del concreto. El modelo YOLO aplicado para la detección multiescala permitió localizar con precisión los daños presentes en las imágenes del puente, y la integración de los módulos C3k2, SPPF y C2PSA mejoró la identificación de fallas pequeñas como fisuras finas y barras expuestas sin comprometer la eficiencia. Estos resultados coinciden con lo señalado por Du et al. (2022) y con las versiones recientes de la familia YOLO, que han demostrado un mejor rendimiento frente a arquitecturas solo clasificadoras. Además, Yang et al. (2025) destacan que los modelos YOLO son especialmente eficaces en inspecciones con dron por su capacidad de detección en tiempo real y bajo condiciones variables de iluminación, características presentes en las imágenes del Puente Tamborapa.

Los modelos VGG16, MobileNet y DenseNet121 y Yolo v11 permitió analizar su comportamiento en términos de pérdida, exactitud y F1-Score durante el entrenamiento, facilitando la comparación de su estabilidad y capacidad de generalización en la identificación

de fallas del Puente Tamborapa. El modelo VGG16 obtuvo una precisión del 90% y un F1-Score de 82.5%, resultados que resultan inferiores a los reportados por Dorafshan et al. (2018), quienes reportaron precisiones entre 92% y 94% para modelos basados en VGG, superando entre 2 y 4 % a los resultados obtenidos en este estudio. Cha et al. (2017) obtuvieron F1-Scores superiores al 88% en la identificación de grietas mediante arquitecturas tipo VGG entrenadas en condiciones controladas, lo que representa una diferencia aproximada de 5.5 % al F1-Score alcanzado por VGG16 en la validación del Puente Tamborapa. Xu et al. (2019) obtuvieron una precisión del 96.37% en la detección automatizada de grietas en puentes empleando una red neuronal convolucional, demostrando la efectividad de estas arquitecturas para identificar daños en infraestructura real. Este valor se encuentra por encima del 90% alcanzado en el presente estudio con el modelo VGG16; sin embargo, ambas investigaciones coinciden en que las CNN poseen un alto potencial para la identificación de fallas en puentes. La ventaja de este modelo es que permite procesar imágenes de los daños del puente, en formato 224×224 píxeles, con una precisión de 91 %, y procesa una cantidad de parámetros 138 millones en tiempo de 20 minutos. Teniendo como desventaja un desempeño inferior en comparación con otros modelos y alto costo computacional en comparación a otras CNN.

El modelo MobileNet mostró un desempeño superior al de VGG16 en términos de precisión, alcanzando un 94%, mientras que el F1-Score se mantuvo en 82.5%, igual que VGG16. Estos resultados reflejan una mayor capacidad de generalización para la detección de fallas en el Puente Tamborapa. Howard et al. (2017) reportaron precisiones cercanas al 93% al aplicar MobileNet en clasificación de imágenes en condiciones de recursos limitados, lo que indica que los resultados de este estudio superan, Hui et al. (2025), quienes demostraron que MobileNet alcanza F1-Scores entre 80% y 85% en la identificación de grietas y corrosión superficial en concreto, valores semejantes de 82.5% obtenidos en este estudio. Yang (2024) reporta una precisión de validación de 99.38% al emplear MobileNetV2 con transferencia de

aprendizaje para detección automática de grietas en concreto, lo que demuestra que una arquitectura ligera puede alcanzar un desempeño muy elevado. En comparación, el 90% obtenido en este estudio para el puente Tamborapa indica que, aunque el rendimiento es algo más conservador, los resultados están dentro del rango esperado para aplicaciones reales especialmente considerando las variaciones de superficie, condiciones ambientales y complejidad estructural propias de un puente. La principal ventaja del modelo MobileNet es su bajo costo computacional, lo que permitió reducir el tiempo de entrenamiento y el uso de recursos de hardware. El modelo alcanzó una precisión del 94 % y un F1-Score de 82.5 %, superando a VGG16 en exactitud. como desventaja fue que el F1-Score no mostró mejoras, lo que indica que, aunque es eficiente, su capacidad para equilibrar precisión y exhaustividad en la detección de daños fue limitada.

El modelo **DenseNet121** mostró un desempeño sólido en la identificación de fallas , alcanzando una **precisión del 92%** y un **F1-Score de 82.5%**. Estos resultados reflejan la capacidad de la arquitectura para capturar patrones complejos y texturas irregulares presentes en las imágenes del Puente Tamborapa. Ma et al. (2023) reportaron precisiones superiores al 92% y F1-Scores alrededor de 85% en la detección automática de grietas en puentes utilizando arquitecturas basadas en DenseNet, valores que son consistentes con los obtenidos en el presente estudio en el Puente Tamborapa, donde se alcanzó una precisión de aproximadamente 90% y un F1-Score de 82.5%. De manera similar, Kao et al. (2023) lograron precisiones de **92–93%** en la detección de daños con texturas irregulares, muy cercanas al **92%** obtenido en este estudio. La principal ventaja del modelo DenseNet121 es su capacidad para identificar patrones complejos y texturas irregulares, lo que favoreció la identificación de daños como corrosión y eflorescencia, con una precisión del 92 % y un F1-Score de 82.5 %. Como desventaja, requirió un mayor costo computacional que MobileNet, sin presentar mejoras significativas con respecto a las otras clases.

El modelo YOLO (You Only Look Once) obtuvo una precisión de 96.1 % y un F1-Score de 96 %, mostrando un desempeño superior al reportado por Zhang et al. (2023), quienes alcanzaron una precisión de 93.96 % y un F1-Score de 92 % utilizando un modelo YOLOv4 optimizado para grietas en puentes, mientras que Zhou et al. (2025) obtuvieron una precisión de 96.79 % y un F1-Score de 88.51 % en la detección de grietas en puentes mediante una red de detección optimizada. Estos resultados confirman que el desempeño del YOLO empleado en este trabajo se sitúa en el rango más alto de eficiencia. La ventaja de YOLO es su alto desempeño y capacidad de detección en tiempo real, permitiendo localizar y clasificar simultáneamente los daños presentes en una misma imagen, con una precisión (96.1 %) y el F1-Score (96 %), reduciendo el tiempo total de procesamiento por imagen. Como desventaja, este modelo requiere una configuración compleja de los hiperparámetros, lo que aumenta el costo computacional del entrenamiento.

V. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

- El análisis visual y fotográfico permitió establecer un diagnóstico claro del estado del Puente Tamborapa, identificándose daños recurrentes como corrosión, eflorescencia, grietas, exposición de barras y desplazamientos. La alta frecuencia de corrosión (≈ 900 casos), seguida de eflorescencia (≈ 400) y grietas (≈ 390), confirma que el puente presenta un deterioro acelerado asociado a la acción de agentes ambientales húmedos y al desgaste estructural progresivo, coherente con patologías típicas de puentes de concreto expuestos a condiciones fluviales. Estos resultados evidencian que el deterioro se encuentra distribuido tanto en la superestructura como en la subestructura, mostrando patrones compatibles con procesos de fatiga, pérdida de recubrimiento y deformaciones en zonas de apoyo.
- La recolección de 683 imágenes mediante dron permitió obtener un registro exhaustivo, nítido y de alta resolución de las patologías del puente, capturando daños en zonas inaccesibles mediante inspección terrestre. La capacidad del dron para obtener imágenes detalladas (4032×2268 px) hizo posible identificar fallas finas como grietas delgadas, corrosión localizada y desprendimiento de recubrimiento, garantizando una cobertura completa de la estructura. La sistematicidad en la captura y la calidad visual lograda proporcionaron una base robusta y confiable para el posterior entrenamiento de los modelos de aprendizaje profundo.
- La generación de modelos de redes neuronales convolucionales evidenció que cada arquitectura presentó fortalezas específicas en la identificación de fallas del puente. VGG16 mostró eficacia en la extracción de características jerárquicas, MobileNet destacó por su eficiencia computacional y buen desempeño con imágenes de alta

resolución, DenseNet121 demostró gran capacidad para reconocer texturas complejas asociadas a eflorescencia y corrosión, y YOLO sobresalió en la detección localizada de defectos pequeños como grietas y barras expuestas. La diversidad de arquitecturas probadas permitió validar que la combinación de imágenes aéreas y modelos CNN es adecuada para el análisis automatizado de daños en infraestructura.

- La validación de los modelos demostró un desempeño diferenciado, donde YOLO obtuvo los mejores resultados con una precisión de 96.1% y un F1-Score de 96%, superando los rendimientos reportados en investigaciones previas. MobileNet alcanzó la mayor precisión entre los modelos clasificadores (94%), mientras que VGG16 y DenseNet121 lograron precisiones de 90% y 92% respectivamente, con un F1-Score común de 82.5%. Estos indicadores confirman que las arquitecturas evaluadas pueden identificar con confiabilidad los cinco tipos de fallas analizadas, y que el uso combinado de clasificación y detección proporciona un sistema robusto y eficiente para apoyar la inspección estructural del Puente Tamborapa.

5.2.Recomendaciones

- Se recomienda implementar un programa de mantenimiento preventivo y correctivo para atender prioritariamente los daños más recurrentes, especialmente la corrosión, eflorescencia y grietas, debido a su elevada frecuencia e impacto en la durabilidad del Puente Tamborapa. Este programa debería incluir limpieza y sellado de superficies, reparación de recubrimientos deteriorados, tratamiento anticorrosivo en zonas críticas y corrección de desplazamientos en apoyos y juntas, con el fin de reducir la progresión del deterioro en la superestructura y subestructura.

- Se sugiere mantener el uso de drones como herramienta estándar de inspección, ya que demostró ser altamente eficientes para registrar daños en zonas de difícil acceso. Para optimizar estas inspecciones, se recomienda establecer rutas de vuelo periódicas, protocolos de captura con resolución mínima de 12 MP y almacenamiento sistemático de imágenes, permitiendo comparar cambios en el tiempo y fortalecer el seguimiento de patologías .
- Se recomienda profundizar en el desarrollo y ajuste de modelos de redes neuronales convolucionales, aprovechando las fortalezas complementarias de VGG16, MobileNet, DenseNet121 y YOLO. La integración de estas arquitecturas en un sistema unificado permitiría mejorar la precisión en la identificación de texturas complejas, defectos pequeños y patrones jerárquicos de daño, potenciando su uso como herramienta de apoyo para evaluaciones automatizadas en puentes y otras infraestructuras.
- Se recomienda implementar un sistema de monitoreo asistido por inteligencia artificial, utilizando preferentemente el modelo YOLO debido a su mayor precisión y capacidad para detectar y localizar daños en tiempo real. Este sistema debería integrarse con inspecciones programadas por dron, permitiendo generar alertas tempranas, reducir tiempos de diagnóstico y complementar la inspección visual tradicional con análisis automatizados altamente confiables.

VI. REFERENCIAS BIBLIOGRÁFICAS

Abdelkader, E. M., Zayed, T., & Faris, N. (2023). Synthesized Evaluation of Reinforced Concrete Bridge Defects, Their Non-Destructive Inspection and Analysis Methods: A Systematic Review and Bibliometric Analysis of the Past Three Decades. *Buildings*, 13(3), 800. <https://doi.org/10.3390/buildings13030800>

Addisu, E. G., Yirga, T. G., Yirga, H. G., & Yehuala, A. D. (2025). Transfer learning-based hybrid VGG16-machine learning approach for heart disease detection with explainable artificial intelligence. *Frontiers in Artificial Intelligence*, 8. <https://doi.org/10.3389/frai.2025.1504281>

admin. (2025, febrero 19). Puentes críticos en Perú: Infraestructura en riesgo de colapso. <https://infraestructuravial.pe/autopista/puentes-criticos-en-peru-infraestructura-en-riesgo-de-colapso/>

admin. (2025, marzo 6). Mantenimiento predictivo en la industria: Tecnologías y beneficios. *AUTEXOPEN*. <https://www.autex-open.com/sin-categorizar/mantenimiento-predictivo-en-la-industria-tecnologias-y-benefici/>

Aldana-Rodríguez, D., Ávila-Granados, D. L., & Villalba-Vidales, J. A. (2021). *Use of unmanned aircraft systems for bridge inspection: A review*. *DYNA*, 88(217), 32-41. <https://www.redalyc.org/articulo.oa?id=49671281004>

Alderson, A. (2021, septiembre 25). La última filtración del DJI Mavic 3 y Mavic 3 Pro revela más especificaciones, SKUs, una fecha de lanzamiento y una imagen práctica. *Notebookcheck*. <https://www.notebookcheck.org/La-ultima-filtracion-del-DJI-Mavic-3-y-Mavic-3-Pro-revela-mas-especificaciones-SKUs-una-fecha-de-lanzamiento-y-una-imagen-practica.565079.0.html>

Alfaro Aliaga, E. S., & Arica Córdova, V. A. (2021). *Evaluación de la condición estructural del Puente Tsej Tsi y propuesta de intervención* [Tesis de pregrado, Universidad Ricardo Palma] Repositorio institucional de la URP. <https://hdl.handle.net/20.500.14138/4712>

Alfaro, M. C., Vidal, R. S., Delgadillo, R. M., Moya, L., & Casas, J. R. (2025). Structural Damage Detection Using an Unmanned Aerial Vehicle-Based 3D Model and Deep Learning on a Reinforced Concrete Arch Bridge. *Infrastructures*, 10(2).

<https://doi.org/10.3390/infrastructures10020033>

Alshammari, A. (2022). Construction of VGG16 Convolution Neural Network (VGG16_CNN) Classifier with NestNet-Based Segmentation Paradigm for Brain Metastasis Classification. *Sensors*, 22(20), 8076. <https://doi.org/10.3390/s22208076>

ISDI España. (2024, agosto 27). *Redes neuronales convolucionales (CNN): Características y usos* / ISDI. *ISDI España*. <https://www.isdi.education/es/?p=26288>

Analuisa-Aroca, I., Vergara-Romero, A., & Pérez Almeida, I. B. (2023). Redes neuronales convolucionales ResNet-50 para la detección de gorgojo en granos de maíz. *Scientia Agropecuaria*, 14(3), 385-394.

<https://doi.org/10.17268/sci.agropecu.2023.034>

Bartra Aguilar, K. R., Montenegro Honores, C. W., Pretell Ramirez, C. A., & Méndez Parodi, R. A. (2023). Desarrollo de un algoritmo de visión artificial con redes neuronales para la detección de grietas en estructuras de hormigón / *INGnosi*, 9(1).

<http://revistas.ucv.edu.pe/index.php/ingnosis/article/view/3171>

Calderón, P. C. (2025, marzo 24). Estos son los puentes en Lima que están en estado crítico: MML ignora advertencias, según Rutas de Lima. *infobae*.

<https://www.infobae.com/peru/2025/03/24/estos-son-los-puentes-en-lima-que-estan-en-riesgo-de-colapso-mml-no-les-realiza-mantenimiento/>

Campos Barragán, O. B. (2018). *Evaluación del daño estructural en un puente mediante redes neuronales profundas convolucionales* [Tesis de posgrado, Universidad de Chile]. Repositorio Institucional de la Universidad de Chile.

<https://repositorio.uchile.cl/handle/2250/168592>

Cao, Q. H., Nguyen, T. T. H., Nguyen, V. T. K., & Nguyen, X. P. (2023). A Novel Explainable Artificial Intelligence Model in Image Classification problem.

(*arXiv:2307.04137*). <https://doi.org/10.48550/arXiv.2307.04137>

Cha, Y.-J., Choi, W., & Büyüköztürk, O. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361-378. <https://doi.org/10.1111/mice.12263>

Chen, L., Chen, W., Wang, L., Zhai, C., Hu, X., Sun, L., Tian, Y., Huang, X., & Jiang, L.

(2023). Convolutional neural networks (CNNs)-based multi-category damage detection and recognition of high-speed rail (HSR) reinforced concrete (RC) bridges using test images. *Engineering Structures*, 276, 115306.

<https://doi.org/10.1016/j.engstruct.2022.115306>

Chollet, F. (2018). Deep Learning with Python. *Manning Publications*.

<https://www.manning.com/books/deep-learning-with-python>

Dorafshan, S., Thomas, R. J., & Maguire, M. (2018). SDNET2018: An annotated image dataset for non-contact concrete crack detection using deep convolutional neural networks. *Data in Brief*, 21, 1664-1668. <https://doi.org/10.1016/j.dib.2018.11.015>

Du, F., Jiao, S., & Chu, K. (2022). Application Research of Bridge Damage Detection Based on the Improved Lightweight Convolutional Neural Network

Model. *Applied Sciences*, 12(12), 6225. <https://doi.org/10.3390/app12126225>

García-González, J. R., & Sánchez-Sánchez, P. A. (2020). Diseño teórico de la investigación: Instrucciones metodológicas para el desarrollo de propuestas y proyectos de investigación

científica. *Información tecnológica*, 31(6), 159-170. [https://doi.org/10.4067/S0718-](https://doi.org/10.4067/S0718-07642020000600159)

07642020000600159

Golewski, G. L. (2023). The Phenomenon of Cracking in Cement Concretes and Reinforced Concrete Structures: The Mechanism of Cracks Formation, Causes of Their Initiation, Types and Places of Occurrence, and Methods of Detection—A Review. *Buildings*, 13(3), 765.

<https://doi.org/10.3390/buildings13030765>

<https://doi.org/10.3390/buildings13030765>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

https://mitpress.mit.edu/9780262035613/deep-learning/?utm_source=chatgpt.com

He, L., Zhou, Y., Liu, L., Cao, W., & Ma, J. (2025). Research on object detection and recognition in remote sensing images based on YOLO. *Scientific Reports*, 15, 14032.

<https://doi.org/10.1038/s41598-025-96314-x>

He, Z., & Zhang, H. (2024). A Method of Concrete Surface Crack Detection Using an

Improved Convolutional Neural Network (CNN) Model. En P. Xiang & L. Zuo (Eds.), *Novel Technology and Whole-Process Management in Prefabricated Building* (pp. 335-345).

Springer Nature. https://doi.org/10.1007/978-981-97-5108-2_36

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision*

Applications. *arXiv:1704.04861*. <https://doi.org/10.48550/arXiv.1704.04861>

Huamancusi Huamaní, K. E. (2024). *Bases metodológicas para la implementación de sistemas de monitoreo de salud estructural de puentes en Perú* [Tesis de posgrado, Pontificia Universidad Católica del Perú]. Repositorio de tesis de la PUCP.

<http://hdl.handle.net/20.500.12404/29918>

Huang, G., Liu, Z., Maaten, L. van der, & Weinberger, K. Q. (2018). Densely Connected Convolutional Networks. *arXiv:1608.06993*. <https://doi.org/10.48550/arXiv.1608.06993>

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261-2269. <https://doi.org/10.1109/CVPR.2017.243>

Hui, L., Ibrahim, A., & Hindi, R. (2025). Computer Vision-Based Concrete Crack Identification Using MobileNetV2 Neural Network and Adaptive Thresholding. *Infrastructures*, 10(2), 42. <https://doi.org/10.3390/infrastructures10020042>

Hussain, M., Thaher, T., Almourad, M. B., & Mafarja, M. (2024). Optimizing VGG16 deep learning model with enhanced hunger games search for logo classification. *Scientific Reports*, 14(1), 31759. <https://doi.org/10.1038/s41598-024-82022-5>

Jiang, Y., Pang, D., & Li, C. (2021). A deep learning approach for fast detection and classification of concrete damage. *Automation in Construction*, 128, 103785. <https://doi.org/10.1016/j.autcon.2021.103785>

Jin, T., Zhang, W., Chen, C., Chen, B., Zhuang, Y., & Zhang, H. (2023). Deep-Learning- and Unmanned Aerial Vehicle-Based Structural Crack Detection in Concrete. *Buildings*, 13(12), 3114. <https://doi.org/10.3390/buildings13123114>

Kao, S.-P., Chang, Y.-C., & Wang, F.-L. (2023). Combining the YOLOv4 Deep Learning Model with UAV Imagery Processing Technology in the Extraction and Quantization of

Cracks in Bridges. *Sensors (Basel, Switzerland)*, 23(5), 2572.

<https://doi.org/10.3390/s23052572>

Li, L.-S., Hui, Y.-X., Wang, J., & Zhang, Y.-J. (2024). Study on unseating prevention for multi-union long simply supported girder bridges under near-fault ground motions. *Heliyon*, 10(17), e36932. <https://doi.org/10.1016/j.heliyon.2024.e36932>

Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L., & Dollár, P. (2014, mayo 1). Microsoft COCO: Common Objects in Context. *arXiv.Org*. <https://arxiv.org/abs/1405.0312v3>

Ma, K., Hao, M., Meng, X., Liu, J., Meng, J., & Xuan, Y. (2024). Coarse–Fine Combined Bridge Crack Detection Based on Deep Learning. *Applied Sciences*, 14(12), 5004. <https://doi.org/10.3390/app14125004>

Ma, K., Meng, X., Hao, M., Huang, G., Hu, Q., & He, P. (2023). Research on the Efficiency of Bridge Crack Detection by Coupling Deep Learning Frameworks with Convolutional Neural Networks. *Sensors*, 23(16), 7272. <https://doi.org/10.3390/s23167272>

Maguiña Asis, M. P. (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 de pregrado, Universidad Peruana de Ciencias Aplicadas]. Repositorio Académico de la UPC. <http://hdl.handle.net/10757/668053>

Mangalathu, S., Jang, H., Hwang, S.-H., & Jeon, J.-S. (2020). Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls. *Engineering Structures*, 208, 110331. <https://doi.org/10.1016/j.engstruct.2020.110331>

Mascia, N. T., & Sartorti, A. L. (2011). Identificación y análisis de patologías en puentes de carreteras urbanas y rurales. *Revista ingeniería de construcción*, 26(1), 05-24.

<https://doi.org/10.4067/S0718-50732011000100001>

Mirboland, M., & Smarsly, K. (2021). BIM-Based Description of Intelligent Transportation Systems for Roads. *Infrastructures*, 6(4), 51. <https://doi.org/10.3390/infrastructures6040051>

Molinari, B. (s. f.). *Las 4 tecnologías para implementar en el transporte este 2023*.

Recuperado 25 de marzo de 2025, de <https://blog.sitrack.com/las-4-tecnologías-para-implementar-en-el-transporte>

Mosqueira Ramírez, R. (2013). *Evaluación de las fallas del Puente Chonta de la red vial Cajamarca – Baños del Inca* [Tesis de pregrado, Universidad de Cajamarca]. Repositorio institucional de la UNC. <http://hdl.handle.net/20.500.14074/569>

Nayır, S., & Yılmaz, Y. (2024). Determination of the efflorescence defects on concrete and plaster surfaces using a novel deep-learning model. *Journal of Structural Engineering & Applied Mechanics (Online)*, 7(2). <https://doi.org/10.31462/jseam.2024.02123135>

Oscó, L. P., Junior, J. M., Ramos, A. P. M., Jorge, L. A. de C., Fatholahi, S. N., Silva, J. de A., Matsubara, E. T., Pistori, H., Gonçalves, W. N., & Li, J. (2021). A Review on Deep Learning in UAV Remote Sensing. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102456. <https://doi.org/10.1016/j.jag.2021.102456>

Palomino Ojeda, J. M., Cayatopa-Calderón, B. A., Quiñones Huatangari, L., Piedra Tineo, J. L., Milla Pino, M. E., & Rojas Pintado, W. (2023). Convolutional Neural Network for Predicting Failure Type in Concrete Cylinders During Compression Testing. *Civil Engineering Journal*, 9(9), 2105-2119. <https://doi.org/10.28991/CEJ-2023-09-09-01>

Parra, A. (2020, abril 24). Muestreo intencional. Características y ejemplos. *QuestionPro*.

<https://www.questionpro.com/blog/es/muestreo-intencional/>

Pecho, Y. (2017). *Importancia del mantenimiento preventivo de puentes en el Perú*. En E.

Carrera (Ed.), *I Congreso Internacional de Ingeniería y Dirección de Proyectos – III*

Congreso Regional IPMA-LATNET (pp. 37–48). Universidad de Piura. Repositorio

Institucional UDEP. <https://hdl.handle.net/11042/3992>

Qassim, H., Verma, A., & Feinzimer, D. (2018). Compressed residual-VGG16 CNN model

for big data places image recognition. *2018 IEEE 8th Annual Computing and Communication*

Workshop and Conference (CCWC), 169-175. <https://doi.org/10.1109/CCWC.2018.8301729>

Rascón-Madrigal, L. H. (2020). Estimación en la Intención de Agarres: Cilíndrico, Esférico y

Gancho Utilizando Redes Neuronales Profundas. *Revista Mexicana de Ingeniería Biomédica*,

41(1), 117–127.

<https://doi.org/10.17488/RMIB.41.1.9>

Rodríguez Ruiz, C. R. (2024). *Diseño estructural de un puente tipo viga-losa ubicado en el*

centro poblado de Jancao Bajo, Amarilis—Huánuco—2022 [Tesis de pregrado, Universidad

de Huánuco]. Repositorio institucional de la UDH.

<https://repositorio.udh.edu.pe/xmlui/handle/20.500.14257/4867>

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2019). *MobileNetV2:*

Inverted Residuals and Linear Bottlenecks (arXiv:1801.04381). arXiv.

<https://doi.org/10.48550/arXiv.1801.04381>

Seo, J., Duque, L., & Wacker, J. (2018). *Drone-enabled bridge inspection methodology and*

application. *Automation in Construction*, *94*, 112–126.

<https://doi.org/10.1016/j.autcon.2018.06.006>

Shen, J., Liu, J., Xu, Y., Jia, K., Wu, F., Chen, W., & Zhu, D. (2021). Corrosion Cracking Process of Reinforced Concrete under the Coupled Effects of Chloride and Fatigue

Loading. *KSCE Journal of Civil Engineering*, 25(9), 3376-3389.

<https://doi.org/10.1007/s12205-021-0768-4>

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>

Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition* (arXiv:1409.1556). arXiv. <https://doi.org/10.48550/arXiv.1409.1556>

Stakeholders. (2025, marzo 13). Crisis en la infraestructura vial: 75 puentes en riesgo exigen intervención inmediata. *Stakeholders*. <https://stakeholders.com.pe/medio-ambiente/ciudades-sostenibles/crisis-en-la-infraestructura-vial-75-puentes-en-riesgo-exigen-intervencion-inmediata/>

Stoilova, V. (2024). Reinforced concrete bridges deterioration processes: A review. *World Journal of Advanced Engineering Technology and Sciences*, 13(2), 001-012.

<https://doi.org/10.30574/wjaets.2024.13.2.0525>

Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-34372-9>

Taboada, A. M. (2022). Fotogrametría en la generación del modelo digital de un terreno mediante drones. *Revista de Investigación Ingeniería y sus Alcances*, 6(14), 124-139.

<https://doi.org/10.33996/revistaingenieria.v6i14.94>

Trach, R. (2023). A Model Classifying Four Classes of Defects in Reinforced Concrete Bridge Elements Using Convolutional Neural Networks. *Infrastructures*, 8(8), 123.

<https://doi.org/10.3390/infrastructures8080123>

Train AI Models: A Complete Guide to Model Training Techniques. (2024, octubre 16). *Labellerr*. <https://www.labellerr.com/blog/everything-you-need-to-know-about-ai-model-training/>

Varillas, C. J. N., Espinoza, M. S. R., Acurio, L. M. H., Rosario, A. S. B., Chavez, J. A. R., Garcia, O. M. S., Estela, K. M. A., & Contreras, M. A. C. (2024). 3D reconstruction of a bridge with concrete damage classification using deep learning. *International Symposium on Automation and Robotics in Construction (ISARC) Proceedings, 2024 Proceedings of the 41st ISARC, Lille, France, 722-729*. <https://doi.org/10.22260/ISARC2024/0094>

Wan, C., Xiong, X., Wen, B., Gao, S., Fang, D., Yang, C., & Xue, S. (2022). Crack detection for concrete bridges with imaged based deep learning. *Science Progress, 105*(4), 00368504221128487. <https://doi.org/10.1177/00368504221128487>

Xu, H., Su, X., Wang, Y., Cai, H., Cui, K., & Chen, X. (2019). Automatic Bridge Crack Detection Using a Convolutional Neural Network. *Applied Sciences, 9*(14), 2867. <https://doi.org/10.3390/app9142867>

Yang, F. (2024). Enhancing Concrete Crack Image Detection Using MobileNetV2 and Transfer Learning. *Frontiers in Science and Engineering, 4*(4), 110-119. <https://doi.org/10.54691/ynk4nf60>

Yang, X., del Rey Castillo, E., Zou, Y., Wotherspoon, L., Yang, J., & Li, H. (2025). Automated Concrete Bridge Damage Detection Using an Efficient Vision Transformer-Enhanced Anchor-Free YOLO. *Engineering, 51*, 311-326. <https://doi.org/10.1016/j.eng.2025.02.018>

Zapata Castañeda, V. A. (2021). *Evaluación técnica del estado actual para definir los niveles de intervención de los puentes vehiculares, ubicados en el tramo Chiclayo – Olmos, región*

de Lambayeque [Tesis de pregrado, Universidad de San Martín de Porres]. Repositorio Académico de la USMP. <https://repositorio.usmp.edu.pe/handle/20.500.12727/10672>

Zhang, J., Qian, S., & Tan, C. (2023). Automated bridge crack detection method based on lightweight vision models. *Complex & Intelligent Systems*, 9(2), 1639-1652. <https://doi.org/10.1007/s40747-022-00876-6>

Zhou, L., Jia, H., Jiang, S., Xu, F., Tang, H., Xiang, C., Wang, G., Zheng, H., & Chen, L. (2025). Multi-Scale Crack Detection and Quantification of Concrete Bridges Based on Aerial Photography and Improved Object Detection Network. *Buildings*, 15(7), 1117. <https://doi.org/10.3390/buildings15071117>

Zoubir, H., Rguig, M., El Aroussi, M., Chehri, A., Saadane, R., & Jeon, G. (2022). Concrete Bridge Defects Identification and Localization Based on Classification Deep Convolutional Neural Networks and Transfer Learning. *Remote Sensing*, 14(19), 4882. <https://doi.org/10.3390/rs14194882>

AGRADECIMIENTO

1 Agradecemos a Dios por brindarnos la protección, la vida la fortaleza y necesaria para llevar a cabo este proyecto tan anhelado. A nuestros padres, por su gran apoyo incondicional y por los consejos y motivaciones en cada momento de este proceso, apoyándonos a cumplir nuestro sueño de convertirnos en ingenieros civiles. A nuestros hermanos, por su respaldo constante y compromiso a lo largo de esta formación.

1 Extendemos nuestro agradecimiento al Dr. José Piedra Tineo y al Ing. Palomino Dr. Manuel Emilio milla pino por su invaluable apoyo, orientación en asesoramiento durante el proceso de investigación.

Agradecemos a la plana de docentes de la Carrera Profesional de Ingeniería Civil de la Universidad Nacional de Jaén, quienes con nos compartieron sus conocimientos rigurosos y precisos que han dejado una huella en nuestra vida para ser mejor en el futuro.

1 Agradecemos profundamente a nuestros compañeros, amigos, personas que nos brindaron su apoyo y confianza, que fueron cruciales durante este proceso. Si bien Reconocemos que el camino no fue fácil mie, pero logramos superar distintas adversidades altas y bajas. Este logro nos enseña a nunca rendirse y a luchar por nuestros sueños.

¡Muchas gracias a todos!

Alvarado Huamán Osmer

Campos Guerrero Emerson Darley

DEDICATORIA

En primer lugar, dedico esta tesis a Dios, por haberme dado la fortaleza, la sabiduría y la perseverancia que necesitaba para encarar y sobrepasar cada reto durante mi educación universitaria. Su guía constante fue el sostén espiritual que me ayudó a conservar la fe, la disciplina y el empeño para lograr esta meta profesional tan importante. Igualmente, dedico este estudio a mis padres Hildebrando y Luz María, quienes, con su ejemplo de vida, sus enseñanzas, valores y apoyo incondicional tuvieron un impacto significativo en mi desarrollo personal y académico; se convirtió en una fuente constante motivación para seguir adelante con dedicación y lograr este objetivo que hoy simboliza el resultado de su entrega y amor.

Osmer Alvarado

Primero que nada, dedico este proyecto a Dios, quien me permitió tener la fortaleza, inteligencia y dedicación necesaria para poder superar y lograr cada obstáculo que se presentó en mi formación académica, gracias a su guía constante fue mi pilar para mantener la fe, la disciplina y la convicción de culminar este importante objetivo profesional. Igualmente, le dedico este esfuerzo a mis padres, Noé Campos Cutín y Marleny Guerrero Armijos, quienes apoyaron incansables, se sacrificaron y confiaron en mí, su amor, valores y estímulos incesantes fueron la clave para seguir adelante y lograr esta gran meta, que hoy vale tanto como sus frutos. su esfuerzo y acompañamiento.

Emerson Campos

ANEXOS

ANEXO 1

UBICACIÓN DEL ÁREA DE ESTUDIO

(PUENTE TAMBORAPA)

Anexo I:

Plano de ubicación geográfica y localización del Puente Tamborapa



DISTRITO DE JAÉN



DISTRITO DE BELLAVISTA



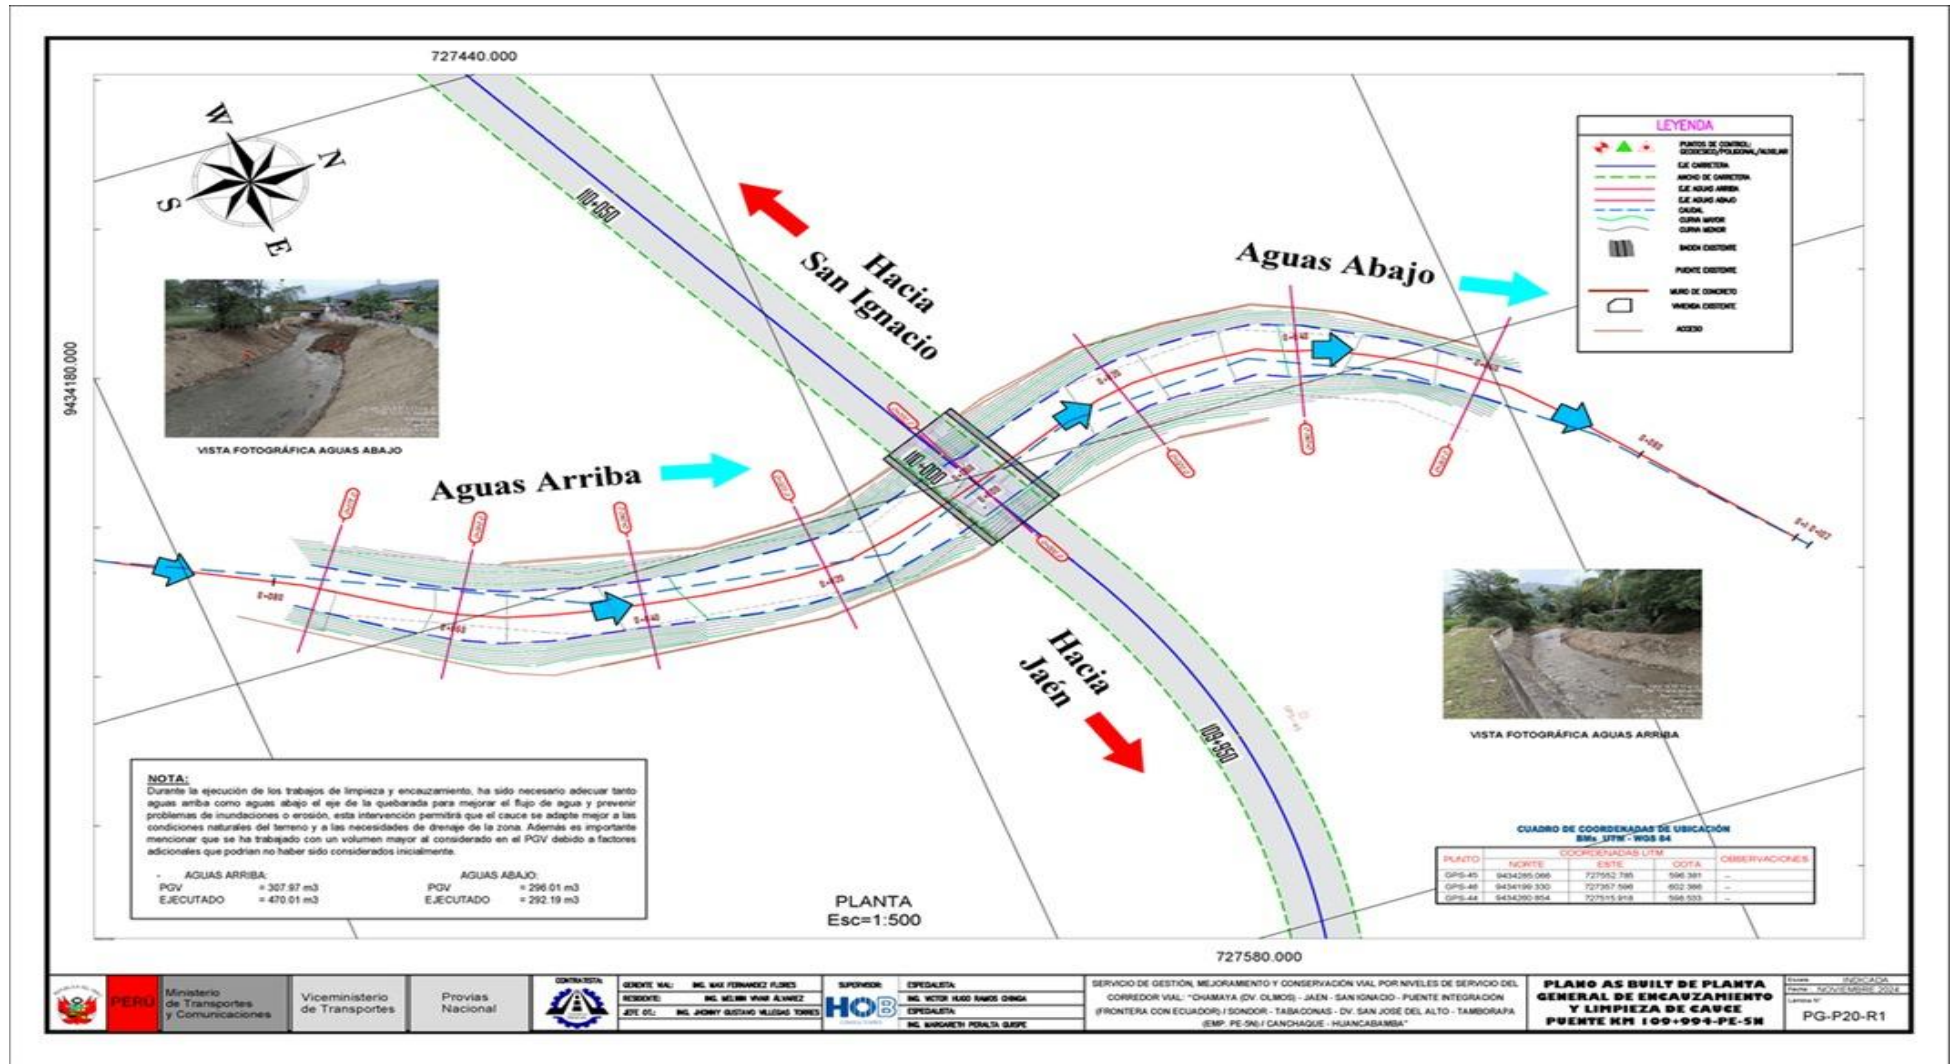
DEPARTAMENTO CAJAMARCA



 UNIVERSIDAD NACIONAL DE JAÉN 		PLANO: UBICACIÓN Y LOCALIZACIÓN	
		UBICACIÓN:	LAMINA:
ESTIMACIÓN DE DAÑOS ESTRUCTURALES EN EL PUENTE TAMBORAPA APLICANDO REDES NEURONALES CONVOLUCIONALES, JAÉN - CAJAMARCA - 2025	PUENTE: TAMBORAPA	DISTRITO: JAÉN	01
	PROVINCIA: JAÉN	DEPARTAMENTO: CAJAMARCA	

Anexo 2:

Ubicación del área de estudio puente Tamborapa



ANEXO 2

EVALUACIÓN Y EDIFICACIÓN DE DAÑOS EN EL PUENTE TAMBORAPA

Anexo 3:

Evaluación de daños de grietas y exposición de barras.





EVALUACIÓN Y IDENTIFICACIÓN EXPOSICIÓN DE BARRAS





Anexo 4:
Evaluación de daños de corrosión.





Anexo 5:
Evaluación de daños de eflorescencia.





Anexo 6:
Evaluación de daños de desplazamientos.






ANEXO 3

RESULTADOS DE LOS MODELOS CNN


3.1 VALIDACION DEL MODELO VGG16

Anexo 7:

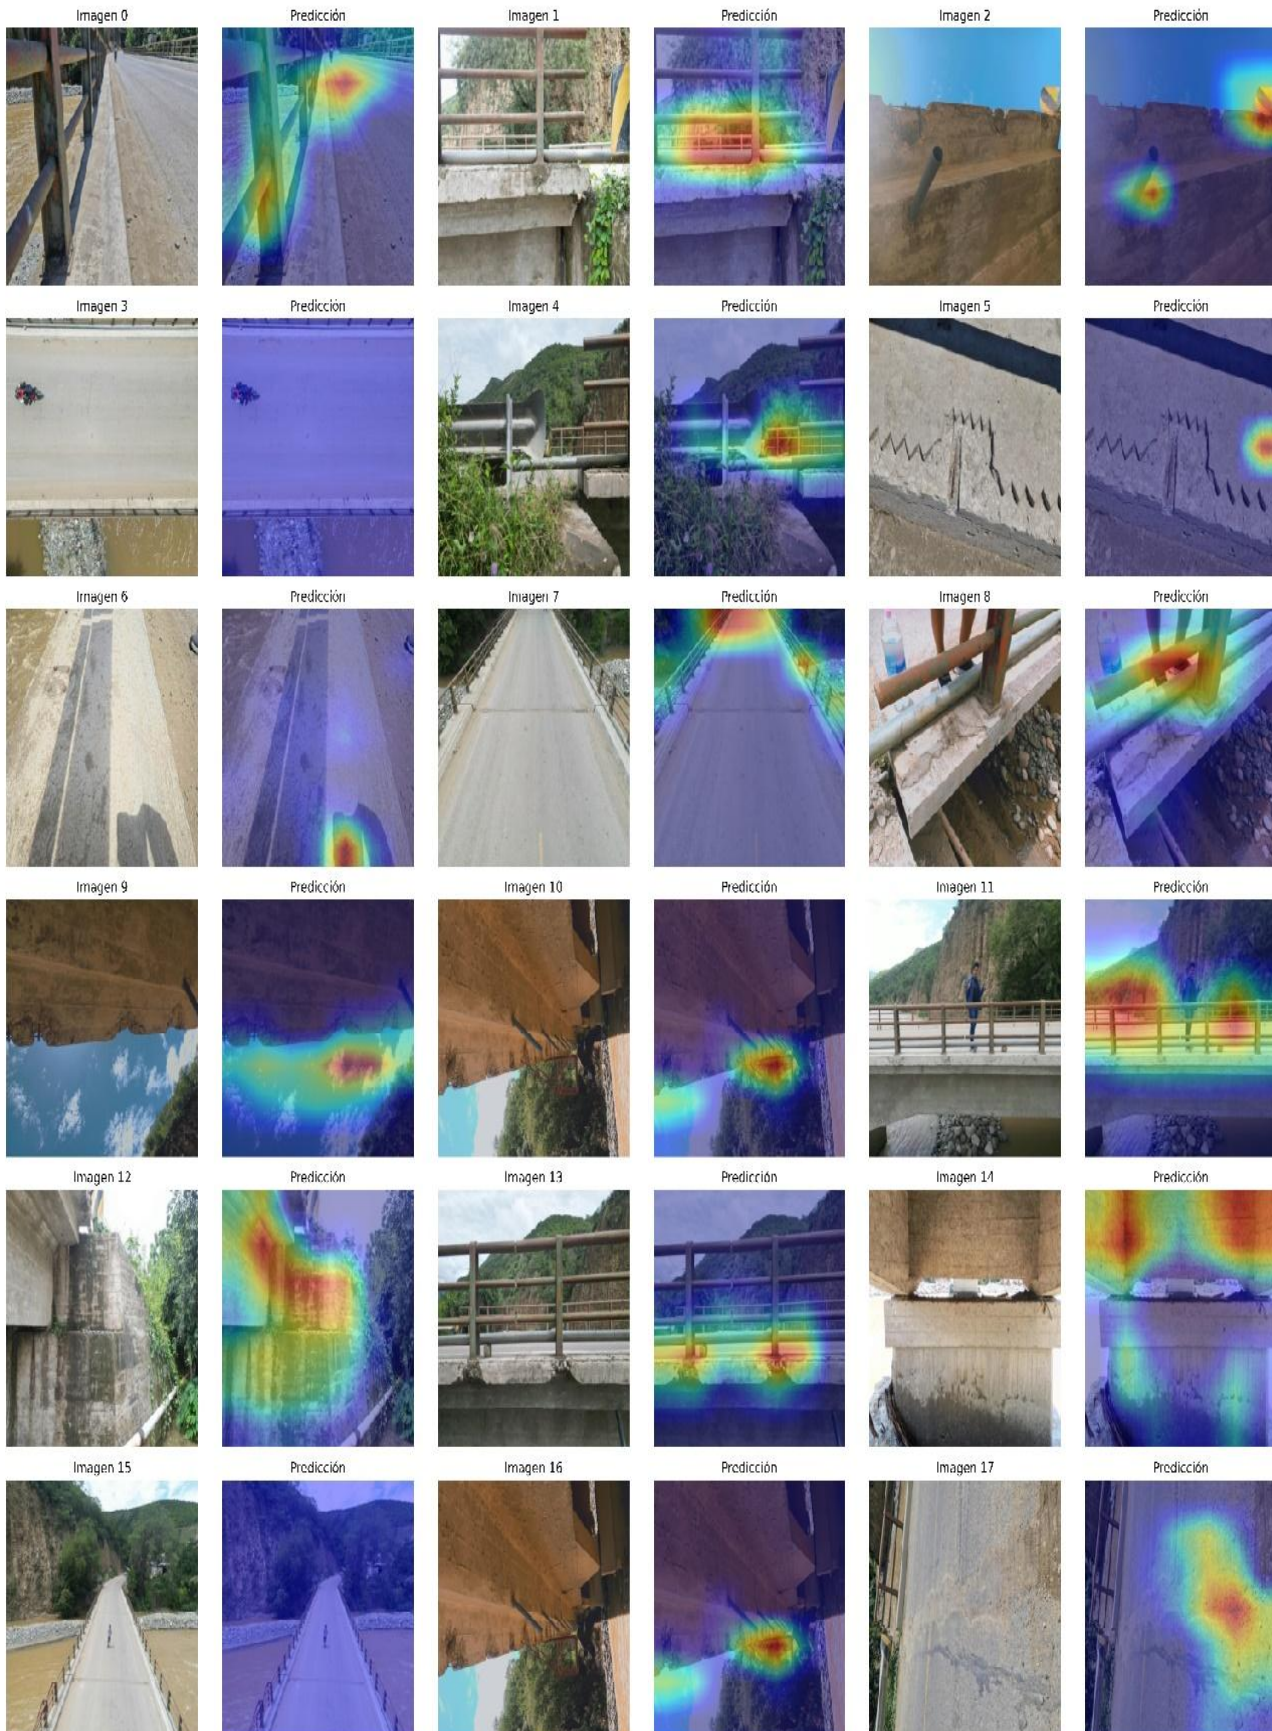
Error, precisión y F1 score del modelo VGG16.



Anexo 8: Detecciones de daños con VGG16



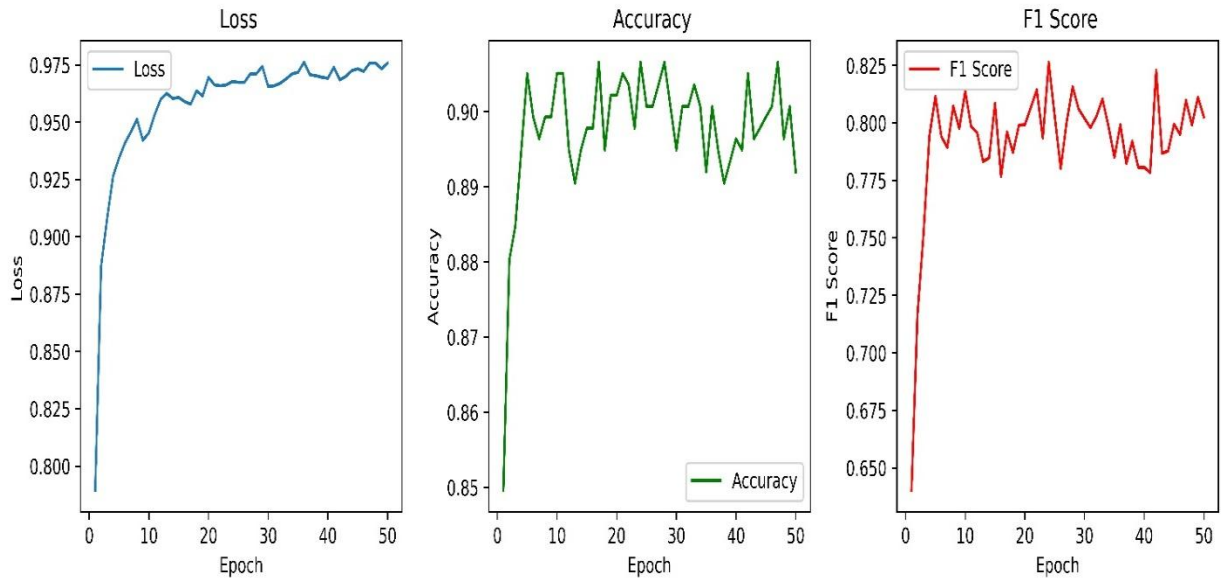
Anexo 9: *Real vs predicho del VGG16*




3.2 VALIDACION DEL MODELO MobileNet

Anexo 10:


Error, precisión y F1 score del modelo Mobilenet.



Anexo 11: Detecciones de daños con MobileNet.



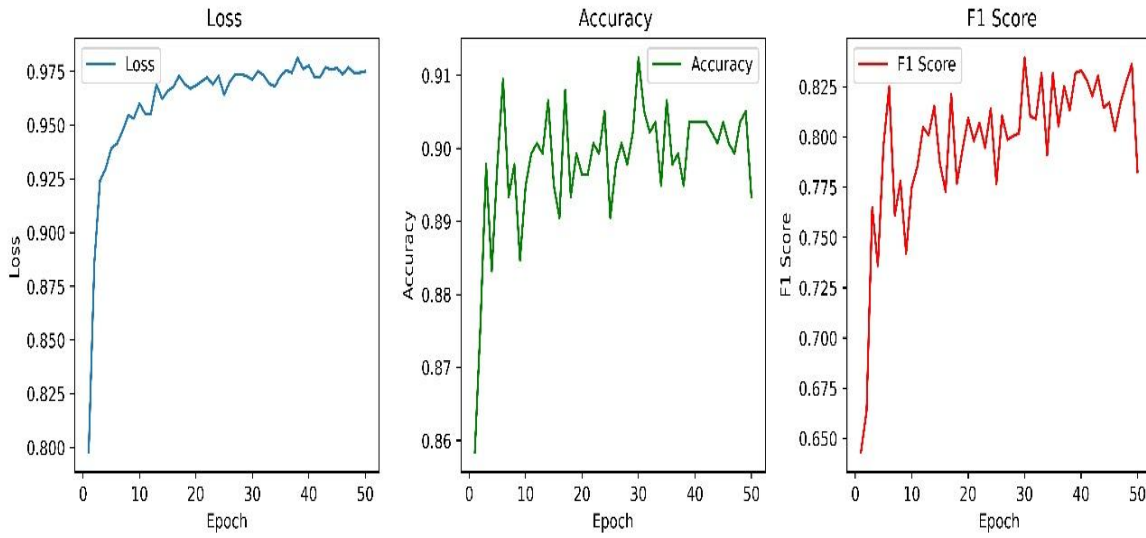
Anexo 12: Real vs predicho de MobileNet



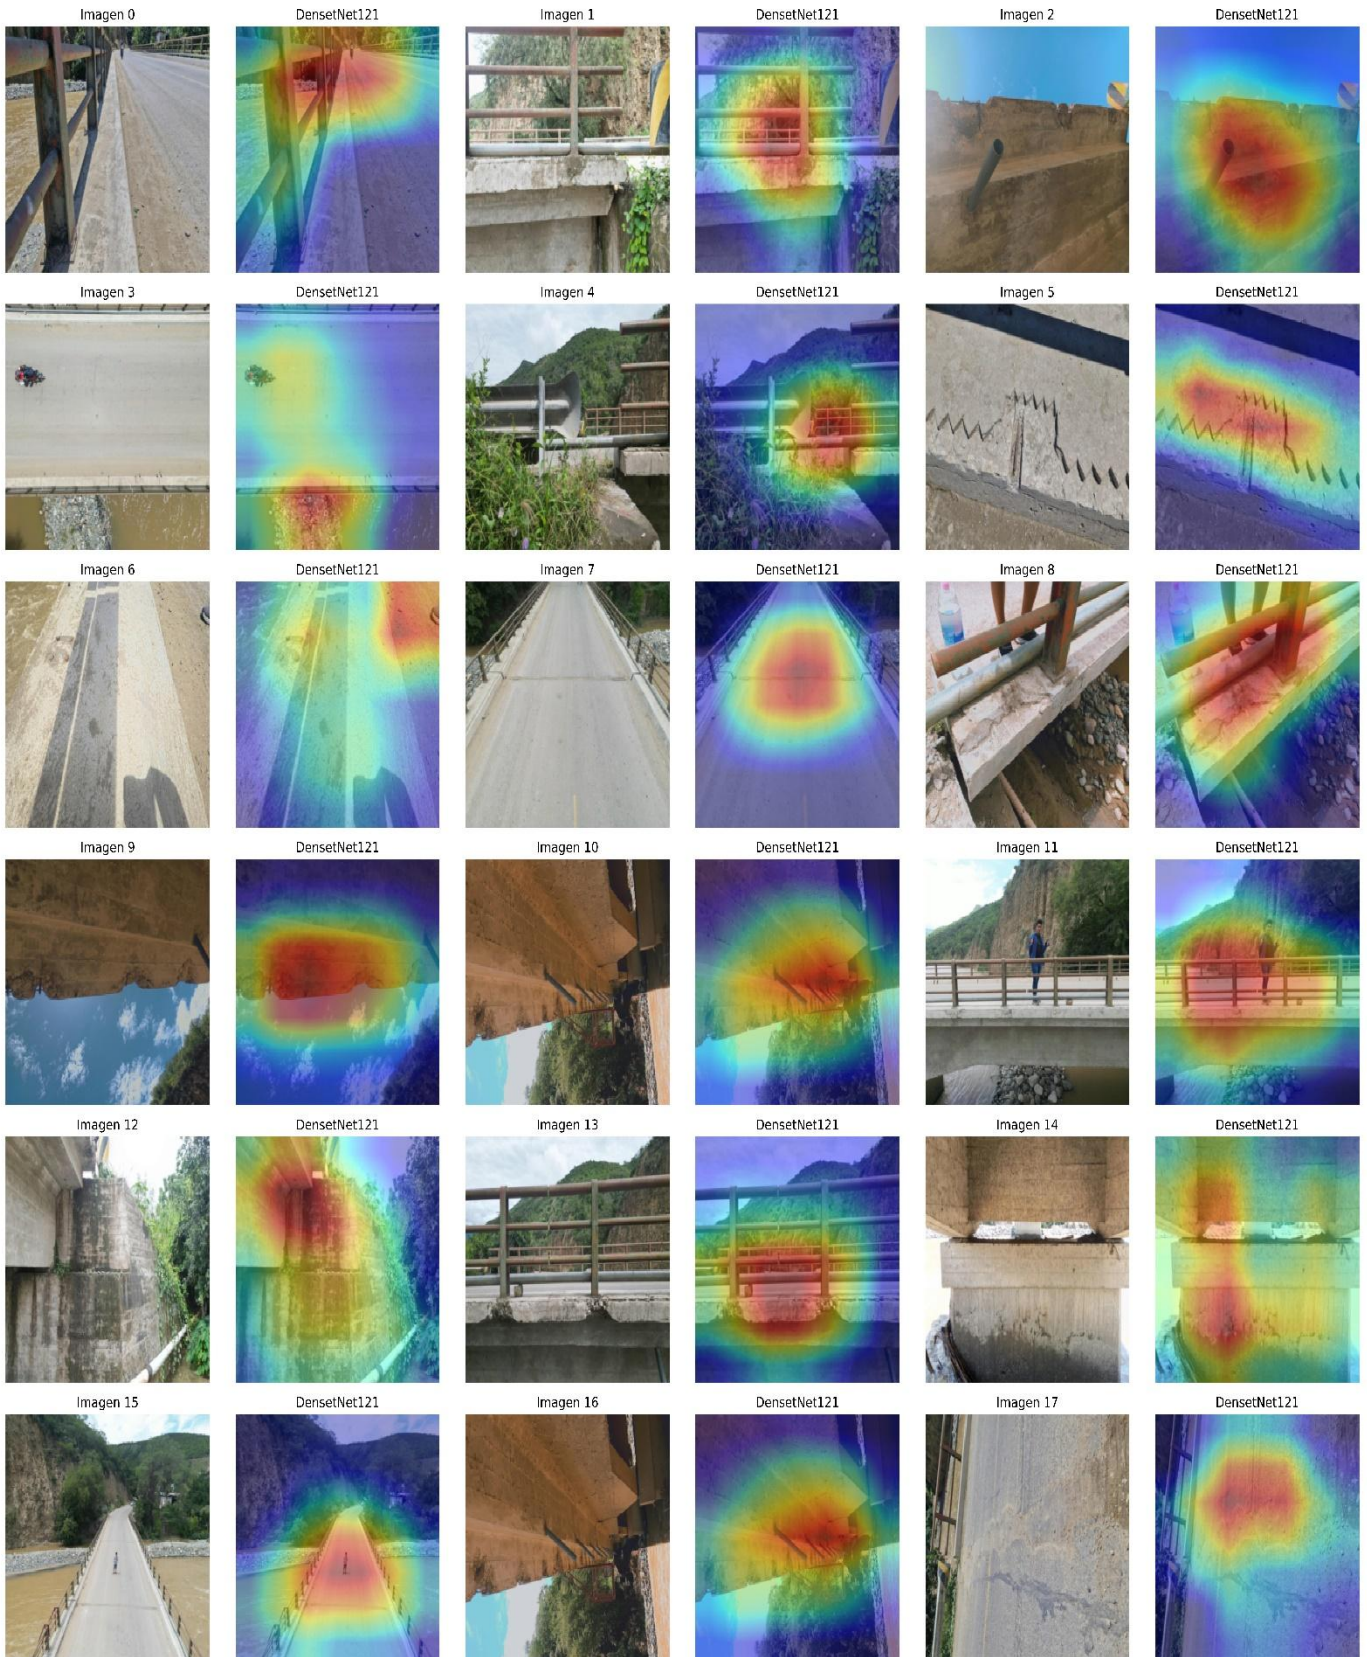
3.3 VALIDACION DEL MODELO DenseNet121

Anexo 13:


Error, precisión y F1 score del modelo DenseNet121



Anexo 14: *Detecciones de daños con DensaNet121*



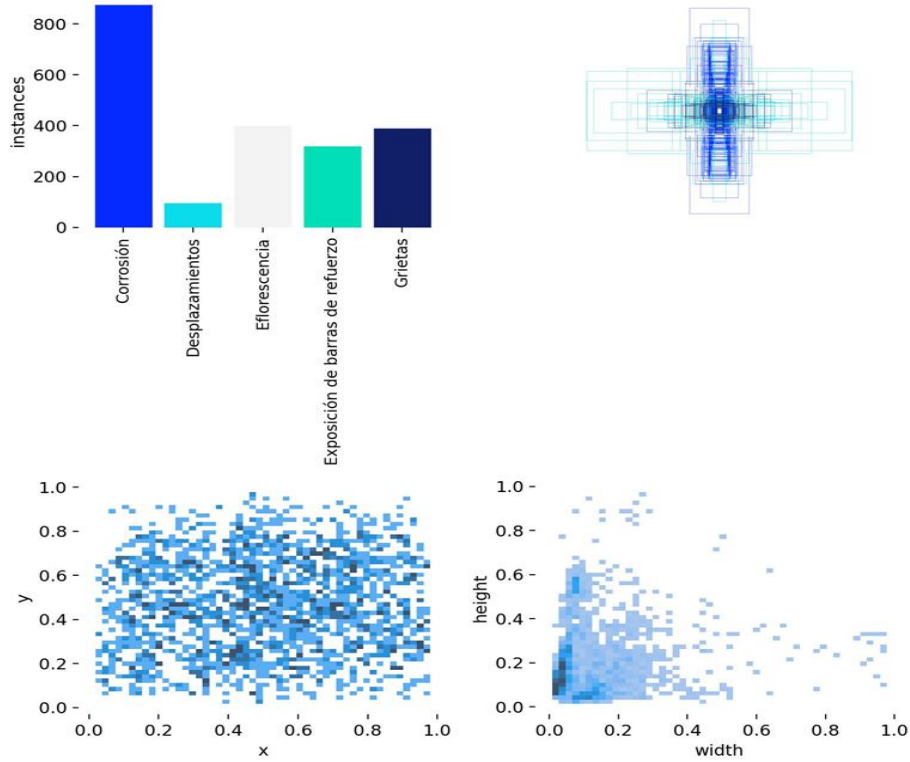
Anexo 15: Real vs predicho del DensaNet121.



3.4 VALIDACION DEL MODELO YOLO

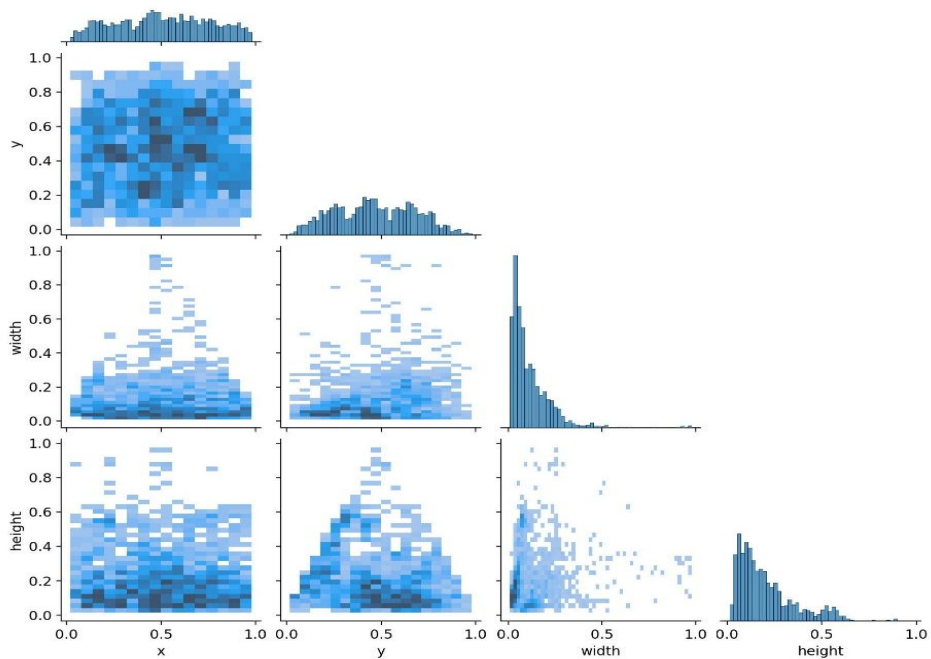
Anexo 16:

Clases de la base de datos

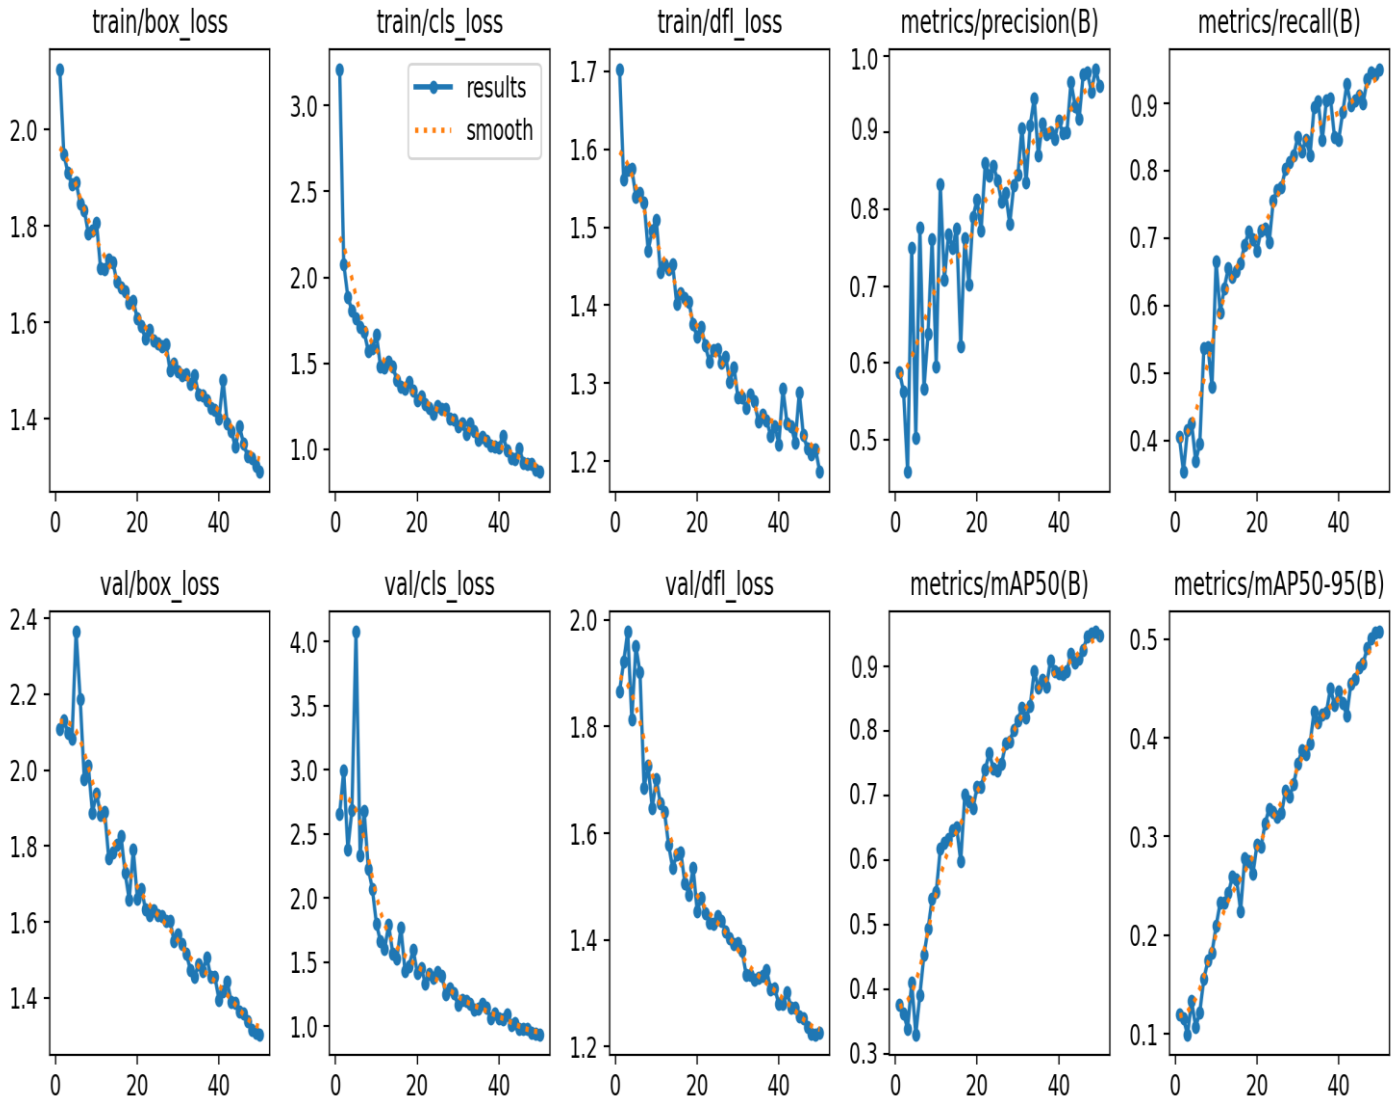


Anexo 17:


Ancho y largo de los pixeles de la base de datos




Anexo 18:
Entrenamiento y validacion de YOLO




Anexo 19:
Curva recall confidencial de YOLO.




Anexo 20:
Curva recall de precisión de YOLO




Anexo 21:
Curva confidencial de precisión de YOLO



Anexo 22:
Curva de F1 score de YOLO.



Anexo 23:
Matriz de confusión de YOLO.



Anexo 24:
Detección de daños en el puente empleando YOLO.



Anexo 25:

Detección de daños en los estribos empleando YOLO.



Anexo 26:
Reconocimiento de daños empleando YOLO.



Anexo 27:
clasificación de daños empleando YOLO



Anexo 28:
 Detección de daños en la plataforma del puente con YOLO



ANEXO 4

CÓDIGO FUENTE DE LOS MODELOS

CNN