

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA

SEDE VIÑA DEL MAR – JOSÉ MIGUEL CARRERA

**“DESARROLLO DE UN MODELO DE INSPECCIÓN DE CORROSIÓN
GALVÁNICA MEDIANTE INSPECCIÓN VISUAL CON INTELIGENCIA
ARTIFICIAL Y VISIÓN COMPUTACIONAL”**

Trabajo de Titulación para optar al título de
INGENIERO EN MANTENIMIENTO
INDUSTRIAL

Alumno:
Sra. Javiera González Montenegro

Profesor Guía:
Mg. Ing. Pablo Andrés Duque Ramírez



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

"DESARROLLO DE UN MODELO DE INSPECCIÓN DE CORROSIÓN GALVÁNICA MEDIANTE INSPECCIÓN VISUAL CON

Título del trabajo: INTELIGENCIA ARTIFICIAL Y VISIÓN COMPUTACIONAL

Nombre del candidato(a): Javiera Alejandra González Montenegro

Carrera / Grado: Ing. Mantenimiento Industrial Modalidad Vespertina

Campus: Sede Viña del Mar

Departamento: Mecánica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Pablo Andrés Duque Ramírez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 23-09-26

Firma:



Estudiante o Candidato(a):

Fecha: 23/09/2026

Firma:

J. Montenegro -
G. González

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

DEDICATORIA

Quiero expresar mi más profundo agradecimiento a mi mamá, quien ha sido un pilar fundamental durante toda mi formación. Gracias por su apoyo incondicional, por acompañarme en cada etapa, por sus palabras de ánimo en los momentos más difíciles y por confiar siempre en mis capacidades. Su esfuerzo, cariño y constante motivación han sido fundamentales para poder llegar hasta esta importante etapa de mi vida.

Agradezco especialmente a mi profesor guía, por su disposición, orientación y conocimientos entregados durante el desarrollo de este trabajo de título. Sus observaciones y recomendaciones fueron fundamentales para mejorar este proyecto y permitieron que pudiera avanzar y enfrentar cada etapa con mayor claridad.

También quiero agradecer a mis compañeros, quienes formaron parte de este proceso académico. Gracias por el apoyo, el compañerismo, los conocimientos compartidos y por todos aquellos momentos de aprendizaje y colaboración que hicieron más llevadero este camino.

Finalmente, agradezco a todas las personas que, de una u otra manera, estuvieron presentes durante mi formación profesional y contribuyeron a que hoy pueda culminar esta etapa. Cada apoyo, enseñanza y palabra de aliento formó parte de este logro, que representa el cierre de años de esfuerzo, aprendizaje y perseverancia.

RESUMEN

La corrosión galvánica se refiere a un proceso de degradación que ocurre cuando diferentes metales hacen contacto eléctrico en un medio electrolítico, lo cual provoca daños específicos en estructuras metálicas. En este estudio se creó y analizó un modelo de inspección visual que utiliza inteligencia artificial y visión computacional para identificar automáticamente la corrosión galvánica en superficies metálicas, con la finalidad de contribuir a los procesos de mantenimiento predictivo en contextos industriales.

La investigación se fundamentó en normas técnicas internacionales, en particular NACE SP21412-2016/SSPC-CPC 1, ASTM G82-98 e ISO 9223, que ofrecieron los parámetros técnicos necesarios para la detección y categorización de este tipo de corrosión. La metodología incluyó la creación de un conjunto de datos equilibrado formado por cinco categorías: corrosión galvánica, corrosión uniforme, picaduras, cavitación y superficies sin corrosión. El modelo se desarrolló mediante el uso de una red neuronal convolucional VGG16, la cual incluye un bloque de atención CBAM, y se aplicaron técnicas de aumento de datos para potenciar su habilidad de generalización.

En un ambiente regulado, el modelo logró una exactitud del 92 % y un F1-score de 0,88 para la categoría de corrosión galvánica. Más tarde, en pruebas llevadas a cabo con imágenes reales tomadas en condiciones no controladas, se logró una precisión general del 67 %, notándose errores que se relacionan principalmente con la confusión en la categoría de cavitación. Estos hallazgos mostraron un rendimiento favorable en situaciones controladas y una reducción en la efectividad del modelo en contextos reales.

En conclusión, se determinó que el modelo creado es técnicamente factible como un recurso para asistir en la inspección visual de la corrosión galvánica. Se identificaron oportunidades de mejora relacionadas con la expansión del conjunto de datos, el procesamiento previo de imágenes y la consideración de arquitecturas más eficaces para su uso en el campo.

TABLA DE CONTENIDO

RESUMEN	3
INTRODUCCIÓN	8
OBJETIVO GENERAL	10
OBJETIVOS ESPECÍFICOS	10
1. CAPÍTULO 1: FUNDAMENTOS Y ANÁLISIS DE NORMATIVAS Y MODELOS DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE CORROSIÓN GALVÁNICA	11
1.1 PLANTIAMIENTO DEL PROBLEMA	12
1.2 CONTEXTO DE LA CORROSIÓN GALVÁNICA	13
1.3 IMPACTO EN INDUSTRIA ESPECÍFICA.....	14
1.4 FACTORES QUE INFLUYEN EN LA FORMACIÓN DE LA CORROSIÓN	15
1.5 MODELO DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE LA CORROSIÓN	17
1.6 APLICACIONES DE LA IA EN LA DETECCIÓN DE LA CORROSIÓN.....	17
1.7 MÉTODOS Y TÉCNICAS PARA LA DETECCIÓN VISUAL DE CORROSIÓN GALVÁNICA.....	17
1.8 INSPECCIÓN VISUAL.....	18
1.9 USO DE IMÁGENES RGB EN LA DETECCIÓN DE CORROSIÓN.	18
1.10 IMÁGENES INFRARROJAS Y DETECCIÓN TÉRMICA.	19
1.11 SOFTWARE Y HERRAMIENTAS ESPECIALIZADAS PARA LA DETECCIÓN DE CORROSIÓN.	19
1.12 SELECCIÓN DEL MODELO DE DESARROLLO	19
1.13 ASPECTOS EVALUADOS PARA LA SELECCIÓN DEL MÉTODO	20
1.14 JUSTIFICACIÓN DEL USO DE IA EN EL MANTENIMIENTO	20
1.15 JUSTIFICACIÓN DE LA ELECCIÓN DE LA NORMATIVA Y DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	21
1.16 CLASIFICACIÓN DE TIPOS DE CORROSIÓN ANALIZADOS MEDIANTE EL MÉTODO SUGERIDO	22
2. CAPÍTULO 2: GENERACIÓN Y ALIMENTACIÓN DE LA INTELIGENCIA ARTIFICIAL.....	24
2.1 BASE TÉCNICA PARA LA IMPLEMENTACIÓN DEL MODELO.....	25
2.2 ENFOQUE DE INSPECCIÓN PROPUESTO.....	25
2.3 APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL MODELO PROPUESTO.	26
2.4 MODELOS DE IA.....	27
2.4.1 COMPARACIÓN ENTRE MODELOS DE IA Y JUSTIFICACIÓN DE LA ELECCIÓN	28
2.5 CASOS DE USO.....	30
2.6 METODOLOGÍAS APLICADAS EN ESTE TRABAJO	32

2.7	ESTRUCRURA DEL CÓDIGO	34
2.8	ORGANIZACIÓN DEL DATASET	44
2.9	ENTRENAMIENTO DEL MODELO	46
2.10	ANÁLISIS DE ERRORES DEL MODELO.....	48
3.	CAPÍTULO 3: EVALUACION DEL MODELO EN PRUEBAS DE CAMPO.	52
3.1	INTRODUCCIÓN A LA EVLUACIÓN DEL MODELO	53
3.2	COMPARACIÓN ENTRE ENTRENAMIENTO Y PRUEBAS DE CAMPO	54
3.3	JUSTIFICACIÓN Y OBJETIVOS DE LAS PRUEBAS DE CAMPO	56
3.4	LIMITACIONES Y OPORTUNIDADES DE MEJORA	57
3.5	RESULTADOS DE LAS PRUEBAS DE CAMPO	58
3.6	ITERACIONES FUTURAS Y PROYECCIÓN DE MEJORAS	62
3.7	IMPACTO DEL MODELO EN LA TOMA DE DECISIONES Y BENEFICIOS OPERACIONALES. 63	
3.8	CONCLUSIONES Y RECOMENDACIONES.....	65
	BIBLIOGRAFÍA.....	67

TABLA DE ILUSTRACIÓN

ILUSTRACIÓN 1 PROCESO DE CORROSIÓN.....	15
ILUSTRACIÓN 2 DISTRIBUCIÓN DE DATASET.....	46
ILUSTRACIÓN 3 GRÁFICO ACCURACY.....	48
ILUSTRACIÓN 4 GRÁFICO LOSS	49
ILUSTRACIÓN 5 MATRIZ DE CONFUSIÓN.....	50
ILUSTRACIÓN 6 ANÁLISIS DE CONFUSIÓN	50
ILUSTRACIÓN 7 MATRIZ DE CONFUSIÓN.....	58
ILUSTRACIÓN 8 PRUEBA DE CAMPO 1	59
ILUSTRACIÓN 9 PRUEBA DE CAMPO 2	59
ILUSTRACIÓN 10 PRUEBA DE CAMPO 3	59
ILUSTRACIÓN 11 PRUEBA DE CAMPO 4.....	60
ILUSTRACIÓN 12 PRUEBA DE CAMPO 5	60
ILUSTRACIÓN 13 PRUEBA DE CAMPO 6	60
ILUSTRACIÓN 14 PRUEBA DE CAMPO 7	61

TABLA DE CONTENIDO

TABLA 1 EJEMPLOS DE PARES GALVÁNICOS DESFAVORABLES COMUNES EN LA INDUSTRIA.....	16
TABLA 2 MODELOS, VENTAJAS Y LIMITACIONES	30
TABLA 3 BLOQUE DE CÓDIGO.....	34
TABLA 4 BLOQUE DE CÓDIGO.....	35
TABLA 5 BLOQUE DE CÓDIGO.....	35
TABLA 6 BLOQUE DE CÓDIGO.....	36
TABLA 7 BLOQUE DE CÓDIGO.....	37
TABLA 8 BLOQUE DE CÓDIGO.....	38
TABLA 9 BLOQUE DE CÓDIGO.....	39
TABLA 10 BLOQUE DE CÓDIGO.....	39
TABLA 11 BLOQUE DE CÓDIGO.....	40
TABLA 12 BLOQUE DE CÓDIGO.....	40
TABLA 13 BLOQUE DE CÓDIGO.....	41
TABLA 14 BLOQUE DE CÓDIGO.....	42
TABLA 15 BLOQUE DE CÓDIGO.....	42
TABLA 16 BLOQUE DE CÓDIGO.....	43
TABLA 17 BLOQUE DE CÓDIGO.....	43
TABLA 18 BLOQUE DE CÓDIGO.....	44
TABLA 19 BLOQUE DE CÓDIGO.....	45
TABLA 20 RESULTADOS ADQUIRIDOS.....	55

SIGLAS

IA:	Artificial Intelligence (Inteligencia Artificial).
ASTM:	American Society for Testing and Materials.
NACE:	National Association of Corrosion Engineers
SSPC:	Society for Protective Coatings
ISO:	International Organization for Standardization
CNN:	Convolutional Neural Networks (Redes Neuronales Convolucionales).
SVM:	Support Vector Machine (Máquina de Vectores de Soporte)
VGG16:	Visual Geometry Group 16.
CBAM:	Convolutional Block Attention Module.
F1-SCORE:	Medida F1

RECALL:	Sensibilidad
PRECISIÓN:	Valor Predictivo Positivo
GPU:	Graphics Processing Unit (Unidad de Procesamiento Gráfico)
COLAB:	Google Colaboratory

TERMINOLOGÍA

DEFECTO: Discontinuidad que excede los límites permitidos por normativas como ISO 3452-2 o ASTM E165/E165M, afectando la seguridad estructural.

DISCONTINUIDAD: Irregularidad en un material que no compromete su integridad, pero puede convertirse en un defecto si supera los criterios normativos.

VISIÓN

COMPUTACIONAL: Rama de la IA que analiza imágenes para la detección automática de defectos en inspecciones industriales.

REDES NEURONALES

CONVOLUCIONALES (CNN): Algoritmos de aprendizaje profundo que identifican y clasifican discontinuidades en soldaduras a partir de imágenes.

CORROSIÓN GALVÁNICA: Ocurre cuando dos metales distintos están en contacto eléctrico en presencia de un electrolito, provocando la disolución del menos noble.

INTRODUCCIÓN

La corrosión galvánica es un problema común en instalaciones industriales que se encuentran en lugares húmedos y marítimos o donde hay sustancias electrolíticas, lo cual impacta directamente la integridad de las estructuras y piezas metálicas. En estas situaciones, identificar a tiempo este tipo de corrosión es fundamental para organizar el mantenimiento, disminuir los costos operativos y evitar fallas en la estructura.

En la actualidad, la detección de corrosión galvánica se lleva a cabo principalmente a través de inspecciones visuales convencionales, realizadas por personal capacitado. Aunque este método es comúnmente empleado, tiene limitaciones significativas, como la dependencia del juicio del inspector, la carencia de seguimiento en los registros, el acceso complicado a áreas importantes y la imposibilidad de llevar a cabo monitoreos constantes en el lugar. Estas limitaciones disminuyen la habilidad para detectar problemas de manera temprana y elevan la duda en el proceso de toma de decisiones sobre el mantenimiento.

Al mismo tiempo, hay normas técnicas como NACE SP21412-2016/SSPC-CPC 1 y ASTM G82, que determinan los criterios para elegir materiales y evaluar el riesgo galvánico. No obstante, estas normas no tratan de forma directa la automatización del procedimiento de inspección visual ni la interpretación sistemática de la evidencia visual en condiciones reales de operación.

Ante esta diferencia, el presente documento sugiere la creación de un modelo de inspección visual automatizada fundamentado en inteligencia artificial y visión computacional, con el objetivo de identificar la corrosión galvánica en superficies metálicas. La metodología incluye la clasificación de un conjunto de imágenes organizadas en diferentes categorías de corrosión, el entrenamiento de una red neuronal convolucional para reconocer patrones visuales específicos y la evaluación del rendimiento del modelo en entornos controlados, así como en situaciones reales de inspección.

Así, la investigación tiene como objetivo proporcionar un recurso técnico que complemente las técnicas tradicionales de inspección, mejorando la objetividad, la

repetibilidad y la habilidad de análisis visual en las aplicaciones relacionadas con el mantenimiento industriales.

OBJETIVO GENERAL

Desarrollar un modelo de inspección basado en inteligencia artificial y visión computacional para apoyar la inspección y detección de corrosión galvánica en estructuras metálicas industriales, orientado a facilitar la inspección técnica y la toma de decisiones en mantenimiento basado en condición.

OBJETIVOS ESPECÍFICOS

1. Analizar normativas técnicas y los enfoques de inteligencia artificial aplicables a la detección de corrosión galvánica fundamentando técnicamente la elección del método de inspección propuesto.
2. Implementar un modelo de visión computacional basado en aprendizaje profundo para la identificación automática de corrosión galvánica a partir de imágenes de superficies metálicas.
3. Evaluar el desempeño del modelo desarrollado mediante métricas cuantitativas y pruebas en condiciones controladas y reales, analizando su aplicabilidad como herramienta de apoyo a la inspección visual tradicional en mantenimiento industrial.

**1. CAPÍTULO 1: FUNDAMENTOS Y ANÁLISIS DE NORMATIVAS Y
MODELOS DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE
CORROSIÓN GALVÁNICA**

1.1 PLANTIAMIENTO DEL PROBLEMA

La corrosión galvánica representa un serio desafío en la industria, ya que daña progresivamente las estructuras metálicas, comprometiendo su integridad y funcionalidad. Este fenómeno se produce cuando dos metales diferentes entran en contacto en presencia de un electrolito, lo que desencadena un flujo de electrones que provoca la oxidación acelerada de uno de los metales. Las consecuencias de este proceso incluyen importantes pérdidas financieras asociadas con reparaciones, reemplazos y tiempos de inactividad.

A pesar de las regulaciones que establecen pautas para la prevención y el control de la corrosión galvánica, la detección temprana y la evaluación precisa siguen siendo tareas desafiantes. La variedad de materiales, las condiciones ambientales adversas y la dificultad de acceso a determinadas zonas potenciales limitan la eficacia de los métodos de inspección tradicionales.

En este contexto, es necesario introducir herramientas avanzadas que puedan superar las limitaciones actuales. El desarrollo de sistemas basados en inteligencia artificial (IA) y visión por computadora ofrece una alternativa innovadora.

La implementación de modelos de inspección automatizados no solo satisface necesidades técnicas, sino que también adapta las prácticas de mantenimiento industrial a las tendencias de digitalización y automatización esenciales en la industria actual.

El principal objetivo del proyecto es desarrollar un sistema capaz de identificar y evaluar la corrosión galvánica, corrosión uniforme, corrosión por picadura, corrosivo por cavitación y el material condiciones normales mediante algoritmos de inteligencia artificial y procesamiento de imágenes, contribuyendo así al avance de las prácticas de mantenimiento y aumentando la sostenibilidad en el sector industrial.

1.2 CONTEXTO DE LA CORROSIÓN GALVÁNICA

En el diseño y el mantenimiento de las estructuras metálicas, la corrosión galvánica es fenómeno electroquímico, que está ampliamente documentado en la literatura técnica. A diferencia de otras formas de corrosión, este tipo de deterioro se manifiesta particularmente cuando la corriente se produce entre varios metales en presencia de electrolitos, lo que provoca pérdidas localizadas al material más activo o menos noble conocido como el ánodo. (ASTM G82-98, 2019)

La norma ASTM G82-98 establece que para que se produzca corrosión galvánica se deben cumplir tres condiciones para que el fenómeno ocurra: la presencia de una diferencia de potencial galvánico entre dos materiales, la presencia de electrolitos que facilita el movimiento iónico y una vía conductora de electrones entre metales involucrados. Sin embargo, la diferencia de potencial por si sola no determina la velocidad de corrosión galvánica, ya que también depende de factores como la polarización de los materiales, las características y conductividad del electrolito. Este manual técnico también advierte que la diferencia de potencial entre los materiales es un factor crítico, cuanto mayor sea la diferencia, más intensa es la tasa de corrosión del ánodo. (ASTM G82-98, 2019)

Además, la norma NACE SP21412-2016/SSPC-CPC 1 propone un método de control preventivo, teniendo en cuenta la evaluación de pares galvánicos de las etapas iniciales de la estructura o componente. Esta planificación incluye la elección de los materiales correctos, un diseño que reduce el contacto eléctrico directo y la introducción de recubrimientos o separaciones dieléctricas, que interrumpe los circuitos galvánicos. (NACE SP21412-2016/SSPC-CPC 1)

1.3 IMPACTO EN INDUSTRIA ESPECÍFICA

La corrosión galvánica representa un riesgo importante, tanto técnico como económico, en múltiples sectores. Esto se debe a su potencial para causar fallas en las estructuras, pérdidas de materiales y problemas en las operaciones. En el ámbito de la infraestructura civil, por ejemplo, edificaciones tales como puentes, túneles y plataformas marinas están continuamente expuestas a la interacción conjunta de la humedad y las sales, lo que acelera el proceso de deterioro cuando diferentes metales se ponen en contacto. La norma ISO 9223 categoriza estos ambientes, especialmente aquellos con alta concentración de cloruros y dióxido de azufre, como las áreas costeras e industriales contaminadas, como muy corrosivos. Un claro ejemplo de esta situación es la rápida corrosión que muestran los tornillos de acero galvanizado cuando están en contacto con acero inoxidable en entornos marinos.

La industria ha documentado que la relación entre aluminio y cobre o latón en equipos eléctricos y mecánicos causa errores prematuros si no están aislados adecuadamente. Según ASTM G82-98, este tipo de combinaciones de metales son una de las más desfavorables desde el punto de vista galvánico. En el área de transporte y aviación, donde los requisitos de peso conducen a metales como aluminio y titanio o acero inoxidable, la combinación de estos materiales puede facilitar la corrosión galvánica. Este fenómeno resulta en una reducción gradual del grosor en las áreas afectadas, la aparición de pequeñas hendiduras y el desarrollo de grietas en la estructura, lo que pone en riesgo la resistencia mecánica de elementos esenciales. Esto no solo amenaza la seguridad de la estructura, sino que también aumenta significativamente los gastos de reparación. Finalmente, desde el punto de vista ambiental y de sostenibilidad, la corrosión galvánica afecta directamente el aumento de los desechos de metales y la demanda de cambios de componentes. Por lo tanto, la norma NACE SP21412-2016/SSPC-CPC 1 recomienda que se incluyan métodos de monitoreo y prueba proactivos, priorizando la elección de materiales compatibles para evitar este tipo de corrosión local.




ILUSTRACIÓN 1 PROCESO DE CORROSIÓN

1.4 FACTORES QUE INFLUYEN EN LA FORMACIÓN DE LA CORROSIÓN

Uno de los principales factores que influyen directamente en la corrosión galvánica es la diferencia de potencial electroquímico entre los metales en contacto. Mientras mayor sea esta diferencia, mayor puede ser la tendencia a que se desarrolle el proceso corrosivo.

Otro factor clave es la relación de zonas entre el ánodo y el cátodo. Una pequeña superficie anódica en contacto con una gran superficie catódica mejora la densidad de corriente del ánodo y acelera su degradación. Este fenómeno es particularmente crítico en los componentes industriales, donde pequeñas piezas de materiales nobles (como tornillos o remaches) están conectados a estructuras metálicas más grandes.

La esencia del electrolito también tiene una gran influencia. La conductividad, el pH, la temperatura y la concentración de sales determinan la velocidad del proceso galvánico. El entorno marino, industrial o de alta humedad promueve la formación de electrolitos en las superficies metálicas. Del mismo modo, las condiciones ambientales, como la temperatura, la humedad, los contaminantes y la presencia de condensación, afectan la activación o

aceleración del proceso. Por ejemplo, en el clima costero, la niebla salina crea las condiciones ideales para la célula galvánica permanece continuamente activa.

La presencia y el estado de los recubrimientos protectores también influyen en el desarrollo de la corrosión galvánica, ya que actúan como una barrera entre la superficie metálica y el medio. Su deterioro de continuidad o la pérdida de esta puede favorecer la exposición del metal y aumentar la posibilidad del proceso corrosivo.

ÁNODO	CÁTODO	EJEMPLOS
Zinc	Cobre	Instalaciones eléctricas.
Aluminio	Cobre-níquel	Cubiertas de aluminio en embarcaciones y tuberías de agua de mar.
Acero al carbono	Acero inoxidable	Soportes estructurales en contacto con pasamanos
Hierro fundido	Latón	Tuberías de agua en contacto con boquillas o válvulas de latón.
Estaño	Plomo	Uniones en techos.

TABLA 1 EJEMPLOS DE PARES GALVÁNICOS DESFAVORABLES COMUNES EN LA INDUSTRIA

Estos factores no solo determinan la formación y la gravedad de la corrosión, sino también su expresión superficial, que es esencial para entrenar algoritmos visuales que pueden reconocer el deterioro de este tipo de imágenes industriales.

1.5 MODELO DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE LA CORROSIÓN

La inclusión de la inteligencia artificial (IA) en los procesos de mantenimiento industrial ha abierto nuevas oportunidades para detectar defectos estructurales tempranos, como la corrosión galvánica. Utilizando métodos como visión computacional, es posible analizar las imágenes digitales y reconocer modelos que se escapan de la percepción humana.

El uso de modelos AI se propone en relación con este proyecto para automatizar el proceso de identificación de la corrosión galvánica.

1.6 APLICACIONES DE LA IA EN LA DETECCIÓN DE LA CORROSIÓN.

En particular, se reconoció que el uso de redes neuronales convolucionales es muy efectivo en una clasificación automatizada de imágenes de superficies metálicas. Estas redes pueden ser entrenadas con bases de datos etiquetadas para identificar visualmente las propiedades de corrosión y, por lo tanto, exceder las restricciones en los métodos tradicionales basados en observaciones humanas.

En la industria, estas aplicaciones ya están integradas en sectores como naval, petrolero, energía e infraestructura civil, donde la seguridad y los requisitos operativos son críticos.

1.7 MÉTODOS Y TÉCNICAS PARA LA DETECCIÓN VISUAL DE CORROSIÓN GALVÁNICA

La detección visual de la corrosión galvánica ha sido históricamente uno de los métodos más utilizados debido a su simplicidad, bajo costo y aplicabilidad en el campo. La norma NACE SP21412-2016/SSPC-CPC 1 respalda el uso de la inspección visual como un método efectivo para la detección temprana si se acompaña de criterios técnicos claros y evaluaciones periódicas.

En los últimos años, este método se ha complementado con herramientas de visión computacional que permite la digitalización e interpretación de imágenes utilizando algoritmos de inteligencia artificial que mejoran el diagnóstico de objetividad y precisión. Además, se incorpora el uso de cámaras multiespectrales e infrarrojas, lo que permite detectar cambios no visibles a los ojos humanos, lo que facilita el monitoreo en las etapas de corrosión iniciales.

1.8 INSPECCIÓN VISUAL.

En la corrosión galvánica, la prueba se centra en la interacción de varios metales, a menudo en conexiones, tornillos, sistemas soldados o de fijación.

Para aumentar su eficiencia, los inspectores usan herramientas como cámaras aumentadas, de alta resolución o microscopio portátil, especialmente en el entorno industrial. En estructuras de acceso difíciles, como torres, canales altos o plataformas marítimas, el uso de drones con cámaras especializadas ha ampliado significativamente el tamaño de esta técnica significativamente.

1.9 USO DE IMÁGENES RGB EN LA DETECCIÓN DE CORROSIÓN.

Las imágenes RGB (RED-GREEN-BLUE) son capturadas por cámaras convencionales. En las tareas de determinar la corrosión galvánica, estas imágenes son útiles para identificar cambios de color y estructuras asociadas con procesos corrosivos. Mediante el uso de algoritmos de inteligencia artificial, como las redes convolucionales, es posible entrenar modelos para reconocer los patrones de deterioro que distinguen entre diferentes tipos de corrosión.

Este tipo de imagen a menudo se usa debido a su fácil recepción y accesibilidad, lo que los convierte en la principal fuente de modelos de clasificación automática para desarrollar plataformas como Google Colab o el entorno de trabajo Python.

1.10 IMÁGENES INFRARROJAS Y DETECCIÓN TÉRMICA.

La termografía infrarroja permite la detección de cambios de temperatura en superficies analizadas. En algunos casos, la actividad asociada a la corrosión galvánica genera ligeros cambios térmicos, los cuales pueden ser captados mediante cámaras infrarrojas. Estas imágenes, procesadas con visión computacional, le permiten identificar áreas de riesgo, incluso antes de que los signos visuales se muestren en el espectro.

Aunque este método requiere un equipo más dedicado, su utilidad en el entorno industrial y la capacidad de detectar la corrosión en las primeras etapas lo convierte en una valiosa herramienta complementaria.

1.11 SOFTWARE Y HERRAMIENTAS ESPECIALIZADAS PARA LA DETECCIÓN DE CORROSIÓN.

En el campo del procesamiento de imágenes y el análisis de datos, hay algunas plataformas que le permiten desarrollar algoritmos de detección de corrosión personalizados. Python es actualmente uno de los idiomas más utilizados con compatibilidad con bibliotecas de inteligencia artificial, como TensorFlow y Keras. Mientras tanto, Matlab es un entorno de programación técnica, que también proporciona herramientas visuales ampliadas para analizar imágenes, aunque esto requiere una licencia comercial.

1.12 SELECCIÓN DEL MODELO DE DESARROLLO

El desarrollo de este trabajo se basa en la implementación de la visión computacional, el cual se ha elegido el método principal para determinar visualmente la corrosión galvánica mediante el análisis de imágenes. Esta elección responde a la necesidad de modernizar los procesos, haciéndolos más objetivos, rápidos y escalables, especialmente en el entorno industrial, donde las inspecciones visuales manuales están limitadas por factores como la disponibilidad, la subjetividad del inspector o la evaluación.

Las redes neuronales han mostrado un rendimiento único en tareas con modelos visuales complejos, como la identificación de áreas corroídas en superficies metálicas. Estas redes permiten extraer propiedades visuales especiales como color, textura, forma y contraste, así entrenando modelos capaces de distinguir entre superficies en buen estado de las afectadas por la corrosión.

La norma NACE SP21412-2016/SSPC-CPC 1 admite métodos de inspección visual como una herramienta básica para el control de la corrosión y enfatiza la importancia de la integración de las nuevas tecnologías en este proceso. Al combinar esto con el potencial de la inteligencia artificial, el método propuesto no solo se esfuerza por aumentar la eficiencia de la operación, sino también estandarizar los criterios de prueba al reducir las variaciones humanas.

1.13 ASPECTOS EVALUADOS PARA LA SELECCIÓN DEL MÉTODO

Asimismo, se han desarrollado modelos basados en redes neuronales en la universidad de Concepción las cuales fueron publicadas en la revista de Marina, estas utilizan aprendizaje profundo para clasificar la corrosión en estructuras metálicas. Estos modelos han demostrado mejoras notables en la calidad, consistencia y estandarización de la identificación de corrosión. (Modelo de clasificación de corrosión basado en Deep Learning, 2024)

1.14 JUSTIFICACIÓN DEL USO DE IA EN EL MANTENIMIENTO

Varios estudios e informes del sector validan esta transformación hacia la digitalización del mantenimiento. De acuerdo con Fractal, la inteligencia artificial utilizada en el mantenimiento facilita el análisis de amplios volúmenes de datos en tiempo real, lo que permite prever fallos y disminuir gastos operativos debido a la automatización de actividades esenciales (El impacto de la inteligencia artificial en el mantenimiento industrial, 2024). De manera similar, un estudio de Inspecnet señala que las inspecciones realizadas con la ayuda de inteligencia artificial permiten acceder a áreas de difícil acceso utilizando drones y cámaras inteligentes, lo que asegura una mayor seguridad, objetividad y continuidad en las

operaciones en comparación con los métodos manuales convencionales (NDT con IA: Automatización para la inspección industrial, 2025).

Además, el uso de la visión computacional y aprendizaje profundo contribuye directamente a las estrategias de mantenimiento predictivos, reduciendo tiempo de paradas no programadas, los costos asociados con las fallas estructurales y aumenta la actividad activa de los industriales críticos. Estas herramientas tecnológicas, al estar capacitadas con imágenes normadas, permite adaptarse a innovaciones técnicas y estándares de calidad y seguridad demandados por la industria.

De esta manera, el uso de IA responde no solo a la necesidad técnica de optimización, sino también a la estrategia de adaptación para los desafíos actuales relacionados con la eficiencia operativa, la sostenibilidad y la gestión inteligente de los activos.

1.15 JUSTIFICACIÓN DE LA ELECCIÓN DE LA NORMATIVA Y DEL MODELO DE INTELIGENCIA ARTIFICIAL.

La selección de las normas y del modelo de inteligencia artificial utilizado en esta investigación se basa en criterios técnicos y metodológicos que aseguran la validez de los resultados obtenidos. Respecto a la regulación, se tomaron en cuenta tres documentos fundamentales por su relevancia y su capacidad de complementariedad:

- A. ASTM G82-98: seleccionada como referencia para entender el comportamiento de los pares galvánicos y los factores que influyen en este fenómeno.
- B. ISO 9223: considerada para contextualizar la influencia de la agresividad ambiental sobre los procesos de corrosión.
- C. NACE SP21412-2016/SSPC-CPC 1: utilizada como referencia para criterios de prevención y control aplicable a estructuras metálicas.

Por lo tanto, la elección de las normas no fue al azar, sino que se basa en la necesidad de examinar el fenómeno desde tres puntos de vista: base electroquímica (ASTM), evaluación ambiental (ISO) y directrices de inspección (NACE).

En relación con el modelo de inteligencia artificial, se eligió utilizar redes neuronales convolucionales (CNN) debido a su aplicación en tareas de clasificación de imágenes y su capacidad para extraer características visuales relevantes de superficies metálicas.

La justificación de esta elección se fundamenta en investigaciones recientes, como el estudio realizado por la Universidad de Concepción, presentado en la Revista de Marina (Modelo de clasificación de corrosión basado en Deep Learning, 2024), en el que se utilizaron redes neuronales convolucionales (CNN) para identificar diversos tipos de corrosión en superficies metálicas, obteniendo resultados alentadores en cuanto a la calidad y la coherencia en la detección.

Por ende, la selección de estas referencias normativas y del enfoque basado en CNN proporciona el sustento técnico y metodológico para el desarrollo del modelo.

1.16 CLASIFICACIÓN DE TIPOS DE CORROSIÓN ANALIZADOS MEDIANTE EL MÉTODO SUGERIDO

El método creado en esta investigación se ha elaborado para categorizar cinco tipos de condiciones en la superficie de componentes metálicos industriales. Estas condiciones han sido elegidas por su importancia técnica, su frecuencia en ambientes de producción y su distinción que se puede observar a través de la inspección visual. Las categorías incluyen: corrosión galvánica, corrosión uniforme, corrosión por picaduras, corrosión por cavitación y una superficie libre de corrosión (estado normal).

La corrosión galvánica es un proceso electroquímico que ocurre cuando dos metales con diferentes potenciales electroquímicos están en contacto eléctrico, en presencia de un electrolito. Bajo esta situación, el metal que es menos noble funciona como ánodo y sufre un desgaste más rápido. Desde una perspectiva visual, se distingue por un ataque específico en

la zona de contacto entre metales distintos, evidenciándose productos de corrosión concentrados en la interfaz y un desgaste asimétrico claramente definido. Este tipo de corrosión es frecuente en conexiones atornilladas, bridas y montajes mixtos.

La corrosión uniforme se presenta como una disminución del material que ocurre de manera bastante uniforme en la superficie expuesta. Es el tipo más frecuente de corrosión y normalmente está relacionado con una exposición extensa a condiciones severas. Visualmente, se distingue por una oxidación persistente, una textura mate generalizada y una reducción de espesor relativamente uniforme, sin áreas específicas de daño profundo.

La corrosión por picaduras es un tipo de daño localizado que provoca pequeñas pero profundas cavidades en la superficie de un metal. Se distingue por la existencia de orificios aislados que presentan una elevada relación entre la profundidad y el diámetro, mientras que la zona adyacente puede parecer estar intacta. Este tipo de daño es especialmente importante debido a su naturaleza oculta y a la capacidad de causar perforaciones sin que se presente un daño superficial amplio que sea evidente.

La corrosión por cavitación se relaciona con sistemas expuestos al flujo de fluidos, tales como bombas, válvulas o impulsores. Este fenómeno ocurre cuando burbujas de vapor colapsan en la superficie de un metal, lo que provoca impactos diminutos y repetidos que desgastan el material. A nivel visual, se distingue por la aparición de numerosos micro hoyos concentrados en áreas de gran flujo o presión, creando una textura irregular que es diferente a la corrosión electroquímica habitual.

Finalmente, la categoría de superficie sin corrosión se refiere a situaciones en las que no se evidencia un daño visible en el material. Incorpora superficies metálicas en perfectas condiciones, con una textura uniforme, sin pérdida de material ni signos visibles de oxidación. La incorporación de esta categoría es esencial para la formación del modelo, dado que facilita la creación de un patrón de referencia y disminuye la posibilidad de errores positivos en situaciones reales.

2. CAPÍTULO 2: GENERACIÓN Y ALIMENTACIÓN DE LA INTELIGENCIA ARTIFICIAL

2.1 BASE TÉCNICA PARA LA IMPLEMENTACIÓN DEL MODELO.

Los principios vinculados a la corrosión galvánica, los factores que influyen en su desarrollo, los métodos de inspección y las normativas aplicables fueron abordados en el capítulo 1. Estos antecedentes constituyen la base técnica para la implementación del modelo de IA propuesto, ya que permite establecer los criterios y características visuales para la clasificación.

Específicamente, ASTM G82-98 proporciona las bases sobre el comportamiento de los pares galvánicos; ISO 9223 ayuda a entender el impacto de las condiciones ambientales en los procesos de corrosión; ISO 8044 ofrece un vocabulario estandarizado relacionado con fenómenos de corrosión; y NACE SP21412-2016/SSPC-CPC 1 presenta información sobre métodos de prevención y control. En este capítulo, no se revisitan estos documentos, sino que se emplean como referencia técnica para guiar la recopilación de datos y la interpretación del fenómeno analizado.

2.2 ENFOQUE DE INSPECCIÓN PROPUESTO

La técnica presentada en este estudio emplea inteligencia artificial y tecnología de visión para respaldar la revisión de superficies metálicas. El enfoque del modelo se dedica al examen de imágenes RGB, con el objetivo de detectar características visuales ligadas a las diversas condiciones analizadas en la investigación: corrosión galvánica, corrosión uniforme, corrosión por picaduras, cavitación y superficies en estado óptimo.

El sistema sugerido no pretende reemplazar la revisión visual llevada a cabo por expertos ni los métodos instrumentales usados para evaluar el estado de los componentes. Su objetivo es complementar el proceso de inspección a través de una clasificación automática de las imágenes, ofreciendo datos adicionales que pueden ayudar en la evaluación técnica y en la toma de decisiones para el mantenimiento basado en condiciones.

A diferencia de la revisión visual convencional, cuya efectividad puede verse afectada por factores como la experiencia del inspector, la luz, la accesibilidad y la visibilidad

de la superficie, el modelo aplica un proceso uniforme de análisis y categorización a las imágenes estudiadas. Sin embargo, su rendimiento también está condicionado por la calidad, variedad y representatividad de las imágenes empleadas durante su entrenamiento, por lo que sus resultados deben interpretarse como datos complementarios en el proceso de inspección.

Por lo tanto, la comparación con la revisión visual convencional propuesta en este estudio es esencialmente conceptual y metodológica. La evaluación práctica se centra en medir el rendimiento del modelo mediante métricas numéricas y pruebas realizadas bajo condiciones controladas y del mundo real, con el fin de evaluar su viabilidad como herramienta de apoyo en la inspección.

2.3 APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN EL MODELO PROPUESTO.

En este proyecto, se utiliza la inteligencia artificial a través de un modelo de visión computacional enfocado en la clasificación automática de imágenes de metales. Para ello, se recurre a un conjunto de datos dividido en cinco clases: corrosión galvánica, corrosión uniforme, corrosión por picaduras, cavitación y superficies en condiciones normales. Las imágenes de estas clases se emplean como datos de entrada en las fases de formación, validación y evaluación del modelo.

El desarrollo se efectúa en Google Colab utilizando Python junto con las bibliotecas TensorFlow y Keras. Se emplea la arquitectura VGG16 mediante aprendizaje por transferencia, a la que se añade un módulo de atención CBAM, diseñado para mejorar la detección de características relevantes en las imágenes. A continuación, el modelo se optimiza y se mide su rendimiento a través de métricas de clasificación que permiten evaluar su habilidad para distinguir entre las cinco clases mencionadas.

De esta forma, la inteligencia artificial se introduce como una herramienta útil en el proceso de inspección, facilitando la clasificación automatizada y consistente de las imágenes evaluadas. Su eficacia se probará tanto con los conjuntos de datos usados en el desarrollo

como con imágenes obtenidas en situaciones reales, con el fin de establecer su capacidad de generalización fuera del entorno controlado.

2.4 MODELOS DE IA

La detección de la corrosión galvánica por inteligencia artificial se ha desarrollado principalmente debido al uso de modelos de entrenamiento profundo, enfatizando las redes neuronales (CNN). Estas arquitecturas resultan ser altamente efectivas en la tarea de clasificar las imágenes, ya que identifican patrones complejos, como por ejemplo los generados por la oxidación, picadura o deterioro localizado de las superficies metálicas.

Las variantes de redes neuronales, como VGGG16, ResNet50 y MobileNetV2, se presentan para los modelos más utilizados, que se han ajustado en trabajos reciente para detectar diferentes corrosivos superficiales. Estas arquitecturas permiten la separación de características como estructuras, colores y geometría irregular relacionada con la corrosión galvánica.

Además, se han realizado métodos híbridos en varios estudios, combinando CNN con métodos de enseñanza controlados, como SVM (apoyo para vectores) o RANDOM FOREST para mejorar la clasificación, especialmente cuando el kit de datos se reduce o desequilibra (Hybrid Model for Detection of Corrosion in Water Pipeline Images Using CNN and Comparing Accuracy with SVM, 2022). En el contexto de esta tesis, la arquitectura CNN está optimizada y entrenada de Google Colab, teniendo en cuenta la eficiencia computacional, la presencia de bibliotecas, como TensorFlow y Keras, y la capacidad de abrir el entorno educativo. La elección del modelo se basa en los criterios exactos, la capacidad de generalizar y compatible con un conjunto de datos visuales.

2.4.1 COMPARACIÓN ENTRE MODELOS DE IA Y JUSTIFICACIÓN DE LA ELECCIÓN

Para elegir la estructura utilizada en el desarrollo del modelo, se evaluaron diferentes redes neuronales convolucionales que ya habían sido entrenadas para tareas de clasificación de imágenes. Las opciones consideradas incluyen VGG16, ResNet50, MobileNetV2 y EfficientNet, cada una con variaciones en cuanto a su profundidad, número de parámetros, nivel de complejidad y requerimientos de procesamiento.

VGG16 tiene una estructura convolucional que sigue un enfoque secuencial y es relativamente simple, lo que facilita su comprensión y su adaptación a través de transferencia de aprendizaje. No obstante, su principal desventaja radica en la gran cantidad de parámetros en comparación con algunas arquitecturas más modernas, lo que resulta en un mayor consumo de memoria y recursos.

ResNet50 presenta conexiones residuales que son útiles para entrenar redes más profundas y permiten una mejor propagación de la información durante el proceso de aprendizaje. Esta arquitectura tiene beneficios para problemas complejos de reconocimiento visual; sin embargo, es más profunda que VGG16 y requiere un enfoque diferente para su ajuste y análisis.

MobileNetV2 fue diseñada con un enfoque en la eficiencia en el uso de recursos, lo que la hace una opción viable para aplicaciones en entornos con recursos limitados, así como en dispositivos móviles o sistemas embebidos. Esta característica la convierte en una ventaja potencial para aplicaciones futuras en el campo, aunque en este caso se eligió una arquitectura que facilitara el desarrollo y análisis del modelo en un entorno de prueba utilizando Google Colab.

EfficientNet aplica un método de escalado que combina la profundidad, el ancho y la resolución de la red, buscando alcanzar una relación efectiva entre rendimiento y uso de recursos. Su inclusión en la discusión permite tener una opción más eficiente; sin embargo,

para este estudio se decidió utilizar VGG16 como base debido a su estructura familiar, su compatibilidad con la transferencia de aprendizaje y su fácil integración con el módulo de atención seleccionado.

Con base en estas reflexiones, se optó por utilizar VGG16 junto con CBAM. VGG16 actúa como extractor de características mediante transferencia de aprendizaje, mientras que CBAM aporta mecanismos de atención tanto a nivel de canal como espacial, con el fin de potenciar las características que son relevantes para la clasificación. Esta combinación se consideró adecuada para distinguir las cinco condiciones superficiales analizadas en el estudio y es compatible con los recursos computacionales disponibles en Google Colab.

La elección efectuada no significa que la combinación de VGG16 y CBAM necesariamente ofrezca un rendimiento mejor que las otras arquitecturas evaluadas, ya que no se llevó a cabo una comparación experimental utilizando el mismo conjunto de datos para todas ellas en esta investigación. Por esta razón, una evaluación comparativa entre varias arquitecturas, así como entre VGG16 con y sin CBAM, constituye una línea de investigación futura para establecer cuantitativamente el aporte de cada configuración.

MODELO	VENTAJAS	LIMITACIONES
VGG16	Arquitectura más simple, fácil de interpretar y ajustar.	Alta carga computacional por el gran número de parámetros, requiere más memorias y recursos.
ResNet 50	Permite redes más profundas con mejor precisión y estabilidad.	Estructuras más complejas, necesita mayor capacidad y puede ser más difícil de ajustar.
EfficientNet	Alta eficiencia y precisión global.	Requiere datasets grandes y hardware especializados, lo que incrementa costos y complejidad de implementación.
MobileNetV2	Optimizado para aplicaciones móviles y sistemas integrados, bajo consumo de recursos, rápido y eficiente.	Menos capacidad para detectar detalles finos y texturas complejas.

TABLA 2 MODELOS, VENTAJAS Y LIMITACIONES

2.5 CASOS DE USO

El de la IA se introduce en diversas industrias que requieren un monitoreo constante de la integridad estructural, especialmente en los casos en que el contacto entre los metales heterogéneos crea condiciones que tienden a la corrosión galvánica, también de activos críticos como tuberías, tanques de almacenamiento, plataformas e intercambiadores de calor. En el sector energético, se han implementado modelos predictivos que emplean visión computacional y métodos de aprendizaje automático para prever fallos, mejorar el

mantenimiento según el riesgo y minimizar los gastos relacionados con interrupciones imprevistas. Estos métodos han permitido realizar inspecciones más frecuentes no invasivas y sin interrupciones, reduciendo significativamente los costos de mantenimiento correctivo y aumenta la seguridad en el trabajo.

En la industria marítima, donde las condiciones de sal intensifican los procesos de corrosión, los modelos de aprendizaje profundo se han utilizado para inspeccionar cascos de barcos, plataformas marinas y estructuras de metales sumergidos. El uso de drones y cámaras térmicas RGB, junto con modelos entrenados para determinar los cambios estructurales y térmicos, ha mejorado la identificación temprana de la corrosión galvánica, especialmente en compuestos metálicos como acero-aluminio o acero-cobre (Fathy, 2023)

Por otro lado, en el sector de la infraestructura civil, los modelos híbridos que combinan redes neuronales convolucionales (CNN) y máquina de vectores de soporte (SVM) tiene un nivel alto de precisión en la clasificación de imágenes de tubos corroídos.

Las CNN son un tipo de modelo de aprendizaje diseñado para el análisis de imágenes ya que extrae características visuales complejas. Por otro lado las SVM corresponden a algoritmos de aprendizaje utilizados para tareas de clasificación cuyo principio se basa en la separación óptima de los datos. Es eficiente cuando se trabaja con conjuntos de datos limitados o desbalanceados.

En el marco de este estudio, las CNN son particularmente valiosas, ya que facilitan la extracción automática de características visuales complejas de superficies metálicas, tales como texturas, patrones de color y geometría relacionada con la corrosión galvánica, sin requerir el uso de descriptores manuales. Luego, el SVM utiliza esas características para clasificar de manera efectiva y objetiva los casos de corrosión en comparación con superficies que se encuentran en buen estado, incluso en situaciones donde la cantidad de datos de entrenamiento es escasa o las clases están desigualmente distribuidas. Esta unión apoya de manera directa los propósitos de la tesis, dado que proporciona un enfoque metodológico que

puede automatizar la revisión visual, disminuir la subjetividad del operador y aumentar la confiabilidad del diagnóstico en situaciones industriales auténticas..

Estos ejemplos demuestran cómo la integración de IA no solo mejora la capacidad de diagnóstico contra la corrosión, sino que también permite los sistemas esperados que optimizan la planificación del mantenimiento, expande el tiempo de uso activo y garantiza la seguridad de la estructura.

2.6 METODOLOGÍAS APLICADAS EN ESTE TRABAJO

El enfoque desarrollado en este estudio se enfoca en la creación, ejecución y evaluación de un modelo de clasificación de imágenes que utiliza aprendizaje profundo para identificar la corrosión galvánica y diferenciarla de otras condiciones de la superficie. Esta investigación adopta un método cuantitativo-exploratorio, apoyándose en técnicas de visión computacional e inteligencia artificial para analizar imágenes de superficies metálicas.

El proceso se llevó a cabo en fases sucesivas que incluyeron la recolección y categorización de imágenes, la estructuración del conjunto de datos, el preprocesamiento, el entrenamiento del modelo y su evaluación posterior. Las imágenes utilizadas fueron principalmente capturadas a través de fotografías realizadas en varios sitios donde se hallaron superficies metálicas con características visuales relacionadas con las condiciones en estudio, sin determinar un lugar específico para la recogida de muestras. Luego, las fotos fueron organizadas y etiquetadas en cinco categorías: corrosión galvánica, corrosión uniforme, corrosión por picaduras, cavitación y superficie normal, tomando en cuenta las características visuales previamente investigadas y delineadas para cada tipo de condición.

Particularmente, para la categoría de corrosión galvánica, se eligieron basándose en características visuales alineadas con este tipo de daño, centrándose principalmente en la presencia de ataque localizado y productos de corrosión en áreas que se vinculan con el contacto entre diferentes materiales metálicos. Por lo tanto, la clasificación que se utilizó para compilar el conjunto de datos se sustentó en criterios visuales y en la literatura técnica

revisada, sin efectuar una verificación a través de pruebas electroquímicas o análisis de laboratorio. Esta situación se considera una restricción en la metodología y debe tenerse en cuenta al analizar los resultados del modelo.

Una vez clasificadas, las imágenes fueron distribuidas en conjuntos separados para entrenamiento, validación y prueba. El conjunto de entrenamiento se destinó al aprendizaje del modelo; el conjunto de validación se utilizó para monitorear su rendimiento durante el desarrollo y ajuste; mientras que el conjunto de prueba se reservó para evaluar después la capacidad del modelo de clasificar imágenes no utilizadas en la fase de entrenamiento. Así, la metodología aplicada corresponde a la división del conjunto de datos y no a un método de validación cruzada.

Como parte del proceso de preprocesamiento, las imágenes se ajustaron a un tamaño de 224×224 píxeles, que es la dimensión relacionada con su inclusión en el modelo. También se implementaron técnicas de aumento de datos para el conjunto de entrenamiento, con el objetivo de enriquecer su diversidad visual y mejorar la capacidad de generalización. Los métodos específicos empleados para preparar las imágenes y realizar el entrenamiento se describen en las secciones posteriores.

Finalmente, se llevó a cabo una evaluación del desempeño del modelo utilizando métricas de clasificación cuantitativas, que incluyeron precisión, exactitud, recall, F1-score y matrices de confusión. Esta evaluación se enriqueció con pruebas realizadas sobre imágenes tomadas en situaciones reales, con el fin de examinar el desempeño del modelo en condiciones distintas a las que se encontraron durante su creación. La comparación con el análisis visual tradicional se aborda principalmente desde una perspectiva tanto conceptual como metodológica, considerando el sistema desarrollado como un recurso complementario para la inspección técnica, en lugar de servir como sustituto del juicio del inspector.

2.7 ESTRUCTURA DEL CÓDIGO

La introducción técnica del modelo de detección de corrosión galvánica propuesto se desarrolló completamente en la plataforma Google Colab, lo que permitió una configuración accesible, portátil y replicable para la ejecución del código. El flujo de programación está estructurado en una variedad de bloques que corresponden a características especiales, desde el procesamiento de imágenes hasta el entrenamiento final del modelo optimizado.

La estructura del código se organizó en bloques, los cuales permiten la implementación modular, clara y replicable.

Nº DE BLOQUE	DESCRIPCION
1	Este primer bloque establece la conexión con Google Drive en el espacio de trabajo de Google Colab, lo que facilita el acceso a los archivos del proyecto, incluyendo el conjunto de datos y el almacenamiento del modelo que ha sido entrenado. También se traen todas las bibliotecas requeridas para el tratamiento de imágenes, la creación del modelo de red neuronal (VGG16), así como para el entrenamiento, la evaluación y la visualización de los resultados. <pre> from google.colab import drive drive.mount('/content/gdrive') from tensorflow.keras.models import Sequential, Model from tensorflow.keras.layers import Conv2D, MaxPool2D, Dense, Flatten, Dropout, BatchNormalization, Input from tensorflow.keras.optimizers import Adam from tensorflow.keras.callbacks import TensorBoard, ModelCheckpoint, EarlyStopping, ReduceLROnPlateau from tensorflow.keras.utils import to_categorical from tensorflow.keras.preprocessing.image import ImageDataGenerator from tensorflow.keras.applications.vgg16 import VGG16, preprocess_input from sklearn.utils import shuffle from sklearn.model_selection import train_test_split from sklearn.metrics import classification_report, confusion_matrix import os import numpy as np import matplotlib.pyplot as plt from PIL import Image %matplotlib inline # Callbacks checkpoint = ModelCheckpoint('/content/gdrive/MyDrive/Proyecto/PRUEBA.h5', monitor='val_accuracy', save_best_only=True, mode='max', verbose=1) early_stop = EarlyStopping(monitor='val_loss', patience=10, restore_best_weights=True) reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=5) callbacks=[reduce_lr, checkpoint] </pre>

TABLA 3 BLOQUE DE CÓDIGO

2	Este bloque tiene la función de revisar todas las imágenes que se encuentran en un directorio de entrada, seleccionando aquellos archivos que son de tipo. jpg y. png, y ajustándolos a un tamaño uniforme de 224x224 píxeles, lo cual es necesario para la arquitectura VGG16. Las imágenes que han sido procesadas se almacenan en un nuevo directorio, asegurando que el conjunto de datos mantenga una resolución consistente.
<pre># BLOQUE 2 from PIL import Image import os input_dir = '/content/gdrive/MyDrive/Proyecto/Pellet/Imágenes' output_dir = '/content/gdrive/MyDrive/Proyecto/Pellet/Imágenes recortadas' target_size = (224, 224) os.makedirs(output_dir, exist_ok=True) file_list = os.listdir(input_dir) for file_name in file_list: if file_name.lower().endswith(('.jpg', '.png')): input_path = os.path.join(input_dir, file_name) output_path = os.path.join(output_dir, file_name)</pre>	<pre>try: img = Image.open(input_path) img_resized = img.resize(target_size, Image.Resampling.LANCZOS) img_resized.save(output_path) print(f"✅ Procesada: {file_name}") except Exception as e: print(f"❌ Error con {file_name}: {e}")</pre>

TABLA 4 BLOQUE DE CÓDIGO

3	Este apartado define las variables esenciales requeridas para el entrenamiento del modelo de inteligencia artificial. Se establece el tamaño de las imágenes de entrada (224x224 píxeles con 3 canales RGB), que es compatible con la estructura de VGG16, así como la cantidad de clases a predecir, relacionadas con los tipos de corrosión que se están estudiando. Asimismo, se ajustan los parámetros de entrenamiento, como el número de épocas y el tamaño del lote, que afectan de manera directa al aprendizaje del modelo. Se indican las rutas de acceso a los conjuntos de datos destinados al entrenamiento y a la validación.
<pre># BLOQUE 3 import os # Dimensiones de entrada para el modelo width_shape = 224 height_shape = 224 input_shape = (height_shape, width_shape, 3) # Número de clases a predecir num_classes = 5 # Entrenamiento epochs = 60 batch_size = 16 # Directorios de datos train_data_dir = '/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/train' validation_data_dir = '/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/val'</pre>	<pre># Verificación de rutas assert os.path.exists(train_data_dir), f"Ruta no encontrada: {train_data_dir}" assert os.path.exists(validation_data_dir), f"Ruta no encontrada: {validation_data_dir}"</pre>

TABLA 5 BLOQUE DE CÓDIGO

4	Se emplean generadores de imágenes (ImageDataGenerator) para cargar de manera automática las imágenes desde carpetas clasificadas por categorías. En la fase de entrenamiento, se utilizan métodos de aumento de datos el fin de optimizar la capacidad de generalización del modelo, mientras que en la validación únicamente se lleva a cabo el preprocesamiento necesario según VGG16. Esto facilita la alimentación del modelo de una manera eficiente y organizada.
<pre> # \ BLOQUE 4 from tensorflow.keras.applications.vgg16 import preprocess_input from tensorflow.keras.preprocessing.image import ImageDataGenerator # ✓ Generadores de imágenes con preprocesamiento VGG16 train_datagen = ImageDataGenerator(preprocessing_function=preprocess_input, rotation_range=10, width_shift_range=0.1, height_shift_range=0.1, zoom_range=0.1, horizontal_flip=True) val_datagen = ImageDataGenerator(preprocessing_function=preprocess_input) # 📁 Cargar imágenes desde carpetas con etiquetas train_generator = train_datagen.flow_from_directory(train_data_dir, target_size=(height_shape, width_shape), batch_size=batch_size. </pre>	<pre> class_mode='categorical', shuffle=True, seed=42) val_generator = val_datagen.flow_from_directory(validation_data_dir, target_size=(height_shape, width_shape), batch_size=batch_size, class_mode='categorical', shuffle=False) </pre>

TABLA 6 BLOQUE DE CÓDIGO

5	Se emplea la arquitectura VGG16 ya entrenada como fundamento del modelo, conservando al principio sus capas inmóviles. Sobre esta estructura, se añade un bloque de atención CBAM para potenciar la detección de características significativas en las imágenes. Posteriormente, se incluyen capas densas y de dropout para la categorización en cinco categorías. Por último, se lleva a cabo la compilación del modelo utilizando el optimizador Adam y la función de pérdida correspondiente a la clasificación multiclase.
<pre> # \ BLOQUE 5 from tensorflow.keras.applications import VGG16 from tensorflow.keras.models import Model from tensorflow.keras.layers import (Dense, Dropout, GlobalAveragePooling2D, Conv2D, Multiply, Add, Reshape, Lambda) from tensorflow.keras.optimizers import Adam import tensorflow as tf from keras.saving import register_keras_serializable # 📌 IMPORTANTE para Lambda # --- Número de clases --- num_clases = 5 # --- ✅ REGISTRO de funciones para Lambda --- @register_keras_serializable() def spatial_avg(x): return tf.reduce_mean(x, axis=-1, keepdims=True) @register_keras_serializable() def spatial_max(x): return tf.reduce_max(x, axis=-1, keepdims=True) # --- CBAM Attention Block --- def cbam_block(input_feature, ratio=8): channel = input_feature.shape[-1] shared_dense_one = Dense(channel // ratio, activation='relu') shared_dense_two = Dense(channel, activation='sigmoid') avg_pool = GlobalAveragePooling2D()(input_feature) max_pool = GlobalAveragePooling2D()(input_feature) avg_out = shared_dense_two(shared_dense_one(avg_pool)) max_out = shared_dense_two(shared_dense_one(max_pool)) </pre>	<pre> channel_attention = Add()([avg_out, max_out]) channel_attention = Reshape([1, 1, channel])(channel_attention) channel_refined = Multiply()([input_feature, channel_attention]) avg_pool_spatial = Lambda(spatial_avg)(channel_refined) max_pool_spatial = Lambda(spatial_max)(channel_refined) concat = Add()([avg_pool_spatial, max_pool_spatial]) spatial_attention = Conv2D(1, (7, 7), padding='same', activation='sigmoid')(concat) refined_feature = Multiply()([channel_refined, spatial_attention]) return refined_feature # --- Modelo --- base_model = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3)) for layer in base_model.layers: layer.trainable = False x = base_model.output x = cbam_block(x) x = GlobalAveragePooling2D()(x) x = Dense(256, activation='relu')(x) x = Dropout(0.4)(x) x = Dense(128, activation='relu')(x) x = Dropout(0.3)(x) x = Dense(64, activation='relu')(x) x = Dropout(0.2)(x) img_output = Dense(num_clases, activation='softmax', name='image_output')(x) model = Model(inputs=base_model.input, outputs=img_output) model.compile(optimizer=Adam(learning_rate=1e-4), loss='categorical_crossentropy', metrics=['accuracy']) model.summary() </pre>

TABLA 7 BLOQUE DE CÓDIGO

6	Este segmento utiliza métodos de aumento de datos para mejorar tanto la cantidad como la variedad de imágenes en el conjunto de entrenamiento. De cada imagen original, se crean automáticamente tres nuevas versiones a través de transformaciones como rotación, desplazamiento, zoom y reflejo horizontal. Las imágenes generadas se almacenan en una nueva carpeta dentro del almacenamiento temporal de Google Colab, organizadas por categorías, lo que facilita su uso posterior en el entrenamiento del modelo.
<pre> # \ BLOQUE 6 import os from PIL import Image from tensorflow.keras.preprocessing.image import ImageDataGenerator import numpy as np # Carpeta origen: imágenes originales input_dir = '/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/train' # Carpeta destino: en la MEMORIA de Colab (NO en el Drive) output_dir = '/content/train_aumentado' # Crear carpeta si no existe os.makedirs(output_dir, exist_ok=True) # \ Generador de aumento datagen = ImageDataGenerator(rotation_range=20, width_shift_range=0.1, height_shift_range=0.1, zoom_range=0.2, horizontal_flip=True, fill_mode='nearest') # Recorre las subcarpetas por clase for class_folder in os.listdir(input_dir): class_input_path = os.path.join(input_dir, class_folder) class_output_path = os.path.join(output_dir, class_folder) if not os.path.isdir(class_input_path): continue os.makedirs(class_output_path, exist_ok=True) </pre>	<pre> for img_name in os.listdir(class_input_path): if not (img_name.endswith('.jpg') or img_name.endswith('.png')): continue img_path = os.path.join(class_input_path, img_name) img = Image.open(img_path).resize((224, 224)) img_array = np.array(img) img_array = img_array.reshape((1,) + img_array.shape) # Generar 3 variantes por imagen i = 0 for batch in datagen.flow(img_array, batch_size=1, save_to_dir=class_output_path, save_prefix='aug', save_format='png'): i += 1 if i >= 3: break </pre>

TABLA 8 BLOQUE DE CÓDIGO

7	El proceso de entrenamiento se lleva a cabo en dos etapas: en la primera se entrenan únicamente las capas más altas del modelo, dejando fija la base VGG16, y luego se desbloquean parcialmente las capas finales para ajustar el modelo al problema particular. Se añaden pesos de clase para solucionar desequilibrios en el conjunto de datos y se implementa un sistema de ajuste automático de la tasa de aprendizaje para optimizar la convergencia y la estabilidad durante el entrenamiento.
<pre> # \ BLOQUE 7 from sklearn.utils import class_weight import numpy as np from tensorflow.keras.callbacks import ReduceLRonPlateau # ✓ Calcular pesos de clase según distribución real class_weights = class_weight.compute_class_weight(class_weight='balanced', classes=np.unique(train_generator.classes), y=train_generator.classes) class_weights = dict(enumerate(class_weights)) # ✓ Callback para reducción de LR reduce_lr = ReduceLRonPlateau(monitor='val_loss', factor=0.3, patience=5, verbose=1, min_lr=1e-6) # ✓ Etapa 1: Entrenar solo la cabeza densa (capas superiores) history1 = model.fit(train_generator, validation_data=val_generator, epochs=10, callbacks=[reduce_lr], class_weight=class_weights </pre>	<pre> # ✓ Etapa 2: Descongelar últimas 10 capas de VGG16 for layer in base_model.layers[-10:]: layer.trainable = True # Compilar nuevamente con tasa de aprendizaje más baja model.compile(optimizer=Adam(learning_rate=1e-5), loss='categorical_crossentropy', metrics=['accuracy']) # ✓ Continuar entrenamiento total (fine-tuning) history2 = model.fit(train_generator, validation_data=val_generator, epochs=50, callbacks=[reduce_lr], class_weight=class_weights) # ✓ Fusionar historiales si deseas graficar todo junto más adelante: history = {} for key in history1.history: history[key] = history1.history[key] + history2.history[key] </pre>

TABLA 9 BLOQUE DE CÓDIGO

8	Este apartado guarda el modelo íntegro que se ha entrenado en Google Drive en formato Keras, lo que facilita su uso para hacer predicciones en el futuro sin tener que realizar un nuevo entrenamiento.
	<pre> # \ BLOQUE 8 model.save("/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/PIXELES.keras", save_format="keras") print("✓ Modelo guardado exitosamente en formato Keras.") </pre>

TABLA 10 BLOQUE DE CÓDIGO

9	Este segmento lleva a cabo predicciones empleando el conjunto de validación y contrasta los hallazgos con las etiquetas verdaderas. De esto, se crea una matriz de confusión que facilita la visualización de aciertos y fallos del modelo para cada categoría. Asimismo, se genera un informe de clasificación que contiene métricas como precisión, recall y F1-score, lo que posibilita un análisis minucioso del desempeño del modelo y la identificación de confusiones potenciales entre distintas clases de corrosión.
<pre># \ BLOQUE 9 from sklearn.metrics import classification_report, confusion_matrix import seaborn as sns import matplotlib.pyplot as plt import numpy as np # 🔍 Predicciones y_pred = model.predict(val_generator, verbose=1) y_pred_classes = np.argmax(y_pred, axis=1) # 📌 Verdaderos valores y_true = val_generator.classes # 🏷️ Etiquetas de clases labels = list(val_generator.class_indices.keys()) # ✅ Validación de consistencia de tamaños if len(y_true) != len(y_pred_classes): print(f"❌ Tamaños inconsistentes: y_true={len(y_true)} / y_pred={len(y_pred_classes)}") else: # 📊 Matriz de Confusión cm = confusion_matrix(y_true, y_pred_classes)</pre>	<pre>plt.figure(figsize=(8,6)) sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=labels, yticklabels=labels) plt.xlabel("Predicción") plt.ylabel("Real") plt.title("Matriz de Confusión") plt.show() # 📄 Reporte detallado print("\n📄 Clasificación detallada:\n") print(classification_report(y_true, y_pred_classes, target_names=labels))</pre>

TABLA 11 BLOQUE DE CÓDIGO

10	Este segmento establece una función que posibilita la representación gráfica del progreso de métricas como perdida y precisión a través de las épocas. Se presentan de manera comparativa los resultados de entrenamiento y validación, lo que ayuda a examinar el aprendizaje del modelo, identificar sobreajuste y valorar su rendimiento a lo largo del proceso de entrenamiento.
<pre># \ BLOQUE 10: Función para visualizar métricas de entrenamiento y validación import matplotlib.pyplot as plt def plotTraining(hist_dict, metric): """ Acepta un diccionario como hist_dict con las métricas. """ train_vals = hist_dict.get(metric) val_vals = hist_dict.get(f'val_{metric}') if train_vals is None: print(f"⚠️ Métrica '{metric}' no encontrada.") return if "accuracy" in metric: train_vals = [v * 100 for v in train_vals] if val_vals: val_vals = [v * 100 for v in val_vals] plt.figure(figsize=(10, 5)) plt.plot(range(1, len(train_vals) + 1), train_vals, '-r', label='Entrenamiento')</pre>	<pre>if val_vals: plt.plot(range(1, len(val_vals) + 1), val_vals, '--b', label='Validación') plt.title(f"({metric.upper()}) por época", fontsize=18) plt.xlabel('Épocas', fontsize=16) plt.ylabel('Porcentaje' if "accuracy" in metric else 'Valor', fontsize=16) plt.legend() plt.grid(True) plt.xticks(fontsize=12) plt.yticks(fontsize=12) plt.show() plotTraining(history, "loss") plotTraining(history, "accuracy")</pre>

TABLA 12 BLOQUE DE CÓDIGO

11

Este segmento utiliza el modelo que ha sido entrenado previamente y lo aplica a imágenes externas obtenidas en situaciones del mundo real.

Cada imagen es importada, ajustada a un tamaño de 224x224 píxeles y tratada antes de ser introducida en el modelo. Después, se presenta la predicción generada junto con el nivel de confianza para cada categoría. Por último, se calculan métricas generales como precisión, informe de clasificación y matriz de confusión, lo que permite examinar el desempeño del modelo en situaciones de prueba en el campo.

```
# BLOQUE 11 - Evaluación robusta de imágenes de campo (solo Galvánica)

import os, cv2, numpy as np, matplotlib.pyplot as plt, seaborn as sns
from keras.models import load_model
from keras.applications.vgg16 import preprocess_input
from sklearn.metrics import classification_report, confusion_matrix, accuracy_score

# Clases en el orden del entrenamiento
names = ['GALVANICA', 'UNIFORME', 'PICADURA', 'CAVITACION', 'NORMAL']

# Modelo
model_path = "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/PIXELES.keras)"
model = load_model(model_path)

img_size = (224, 224)

# Rutas de campo (ajusta si cambia el nombre/caso/extension)
image_paths = [
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba1.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba2.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba3.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba4.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba5.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba6.jpg)",
    "(content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test/Tipol/Prueba7.png)",
]

# Intento de carga tolerante: arma listas solo con las que cargan
loaded_images = []
loaded_paths = []
for p in image_paths:
    im = cv2.imread(p)
    if im is None:
        print(f"⚠ No se pudo cargar la imagen: (p)")
        continue
    loaded_images.append(im)
    loaded_paths.append(p)
```

```
if len(loaded_images) == 0:
    raise RuntimeError("No se cargó ninguna imagen. Revisa las rutas/nombres/extensiones.")

# Etiquetas reales: todas Galvánica -> índice 0
y_true = [0] * len(loaded_images)

# Predicciones
y_pred = []
for i, (im, p) in enumerate(zip(loaded_images, loaded_paths)):
    im_res = cv2.resize(im, img_size)
    x = np.expand_dims(im_res.astype(np.float32), axis=0)
    x = preprocess_input(x)
    probs = model.predict(x, verbose=0)
    pred_idx = np.argmax(probs)
    y_pred.append(pred_idx)

# Mostrar
plt.figure()
plt.imshow(cv2.cvtColor(im_res, cv2.COLOR_BGR2RGB))
plt.title(f"🔍 Predicción: {names[y_pred_idx]} (probs[y_pred_idx]*100:.2f%) (real: {names[y_true]})")
plt.show()

print(f"📄 {os.path.basename(p)}")
for i, cm in enumerate(names):
    print(f"    >>> {cm} (probs[i]*100:.2f%)")
print(f"📊 Predicción final: {names[y_pred_idx]}")

# Métricas (reporte y accuracy)
print(f"📊 RESULTADOS GLOBALES - Imágenes de campo (solo Galvánica)")
from sklearn.metrics import classification_report
print(classification_report(y_true, y_pred, target_names=names, labels=list(range(len(names))))

from sklearn.metrics import confusion_matrix, accuracy_score
cm = confusion_matrix(y_true, y_pred, labels=list(range(len(names))))
acc = accuracy_score(y_true, y_pred)
print(f"📊 Accuracy global (campo): {acc*100:.2f}%")
```

```
plt.figure(figsize=(6,4))
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', xticklabels=names, yticklabels=names)
plt.title("Matriz de Confusión - Campo (Galvánica)")
plt.xlabel("Predicción")
plt.ylabel("Real")
plt.show()
```

TABLA 13 BLOQUE DE CÓDIGO

12	Este segmento organiza y carga el conjunto de datos de prueba utilizando un generador de imágenes que no aplica aumentos, realizando únicamente el preprocesamiento necesario para VGG16. A continuación, se importa el modelo ya entrenado y se realizan predicciones para cada una de las imágenes incluidas en el conjunto de prueba. Al final, se recogen las clases previstas y las verdaderas, lo que facilita una evaluación posterior a través de métricas de rendimiento.
<pre># 📁 BLOQUE 12 from tensorflow.keras.preprocessing.image import ImageDataGenerator from tensorflow.keras.models import load_model from tensorflow.keras.applications.imagenet_utils import preprocess_input import numpy as np # 📁 Ruta al conjunto de test test_data_dir = "/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/test" # 📏 Dimensiones de entrada esperadas por el modelo width_shape, height_shape = 224, 224 batch_size = 32 # 🔄 Generador de datos para test (sin data augmentation) test_datagen = ImageDataGenerator(preprocessing_function=preprocess_input # solo normalización) # 📁 Carga del conjunto de test test_generator = test_datagen.flow_from_directory(test_data_dir, target_size=(width_shape, height_shape),</pre>	<pre>batch_size=batch_size, class_mode='categorical', shuffle=False # necesario para alinear las etiquetas) # 📁 Cargar el modelo entrenado custom_Model = load_model("/content/gdrive/MyDrive/Proyecto/ImágenesMGA/Dataset/PIXELES.keras") # 📁 Obtener predicciones predictions = custom_Model.predict(test_generator, verbose=1) # 📁 Clases predichas y reales y_pred = np.argmax(predictions, axis=1) y_real = test_generator.classes</pre>

TABLA 14 BLOQUE DE CÓDIGO

13	Este segmento produce estimaciones sobre el grupo de validación y las confronta con las etiquetas verdaderas para formar la matriz de confusión. Esta se presenta de manera normalizada, lo que permite examinar el porcentaje de aciertos y fallos entre las diferentes clases. Asimismo, se genera un informe de clasificación con métricas como la precisión, el recall y el F1-score, lo que hace más fácil realizar una evaluación exhaustiva del rendimiento del modelo.
<pre># 📁 BLOQUE 13 from sklearn.metrics import confusion_matrix from mlxtend.plotting import plot_confusion_matrix import matplotlib.pyplot as plt # ✅ Predicciones sobre validación y_pred = model.predict(val_generator) y_pred_classes = np.argmax(y_pred, axis=1) y_true = val_generator.classes # ✅ Calcular matriz de confusión matc = confusion_matrix(y_true, y_pred_classes)</pre>	<pre># ✅ Graficar matriz de confusión plt.figure(figsize=(9, 9)) plot_confusion_matrix(conf_mat=matc, class_names=names, show_normed=True) plt.title("Matriz de Confusión - Validación") plt.tight_layout() plt.show() from sklearn.metrics import classification_report print(classification_report(y_true, y_pred_classes, target_names=names))</pre>

TABLA 15 BLOQUE DE CÓDIGO

14	Este segmento establece una función que permite representar gráficamente la matriz de confusión ajustada, exhibiendo los porcentajes de aciertos y fallos por categoría. La representación visual incorpora etiquetas, colores y cifras dentro de la matriz, lo que ayuda a comprender el rendimiento del modelo y a detectar confusiones entre las distintas clases.
<pre># \ BLOQUE 14 def plot_confusion_matrix(cm, classes, title='Confusion matrix', cmap=plt.cm.Blues): cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis] # Normalización por fila plt.figure(figsize=(8, 6)) plt.imshow(cm, interpolation='nearest', cmap=cmap) plt.title(title, fontsize=20) plt.colorbar() tick_marks = np.arange(len(classes)) plt.xticks(tick_marks, classes, rotation=45, fontsize=12) plt.yticks(tick_marks, classes, fontsize=12) fmt = '.2f' thresh = cm.max() / 2. for i in range(cm.shape[0]): for j in range(cm.shape[1]): plt.text(j, i, format(cm[i, j], fmt), horizontalalignment="center", color="white" if cm[i, j] > thresh else "black", fontsize=12)</pre>	<pre>plt.ylabel('Etiqueta Real', fontsize=14) plt.xlabel('Etiqueta Predicha', fontsize=14) plt.tight_layout() plt.show()</pre>

TABLA 16 BLOQUE DE CÓDIGO

15	Este segmento emplea la matriz de confusión para determinar con precisión los casos en los que el modelo confunde una categoría con otra. Se examinan todas las posibles combinaciones de categorías y se registran solo los errores, mostrando cuántas imágenes fueron clasificadas incorrectamente. Esto facilita la identificación de patrones de confusión y ofrece una mejor comprensión de las deficiencias del modelo.
<pre># \ BLOQUE 15 from sklearn.metrics import confusion_matrix import numpy as np # Matriz de confusión conf_matrix = confusion_matrix(y_true, y_pred_classes) # Análisis de confusión entre clases print("\n Análisis de confusión entre clases:") for i in range(len(names)): for j in range(len(names)): if i != j and conf_matrix[i][j] > 0: print(f"⚠ Se confundieron {conf_matrix[i][j]} imagen(es) de '{names[i]}' como '{names[j]}'")</pre>	

TABLA 17 BLOQUE DE CÓDIGO

16	Este apartado muestra la matriz de confusión normalizada y determina el porcentaje de aciertos (recall) para cada una de las clases, contrastando los aciertos con el número total de imágenes reales en cada categoría. Los resultados se presentan en forma de porcentaje, lo que facilita la evaluación del rendimiento del modelo en cada clase de corrosión.
	<pre> # 📁 BLOQUE 16 # 📊 Mostrar la matriz de confusión plot_confusion_matrix(matc, classes=names, title="Matriz de Confusión Normalizada") # 📈 Calcular porcentaje de acierto (Recall) por clase aciertos_por_clase = np.diag(matc) total_por_clase = matc.sum(axis=1) # 🚫 Evitar división por cero porcentaje_acierto = np.divide(aciertos_por_clase, total_por_clase, out=np.zeros_like(aciertos_por_clase, dtype=float), where=total_por_clase != 0) * 100 # 🖨️ Mostrar resultados por clase print("\n📊 Porcentaje de acierto por clase:") for i, nombre in enumerate(names): print(f"✓ {nombre}: {porcentaje_acierto[i]:.2f}% ({aciertos_por_clase[i]}/{total_por_clase[i]}") </pre>

TABLA 18 BLOQUE DE CÓDIGO

2.8 ORGANIZACIÓN DEL DATASET

Era importante estructurar adecuadamente el conjunto de datos de imagen para garantizar una capacitación efectiva para el modelo de corrosión galvánica. Según las buenas prácticas, la base de datos se organizó manualmente en tres subgrupos principales en: entrenamiento, validación y prueba. Esta separación se realizó en las carpetas independientes de Google Drive para así estar disponibles en Google Colab, lo que permite la integración directa con el flujo del modelo.

Cada subgrupo contiene imágenes clasificadas en cinco carpetas correspondientes a las clases: galvánicamente, uniforme, picadura, cavitación y normal. Este desglose facilita automáticamente el etiquetado mediante `ImageDataGenerator.flow_from_directory()`. Además, las imágenes se dimensionaron a 224x224 píxeles para garantizar la compatibilidad con la arquitectura de entrada del modelo VGG16, como se hace en el bloque 3.

Durante el procesamiento, se implementó una técnica de aumento de datos para el entrenamiento, que generó varias variantes de la imagen utilizando rotación, traslación,

acercamiento y espejo horizontal. Esto le permitió equilibrar el conjunto de datos y mejorar la robustez del modelo.

La separación entre validación y prueba también fue la clave para garantizar la evaluación objetiva del modelo. La validación sirvió para ajustar los parámetros durante el entrenamiento, mientras que el conjunto de prueba permaneció completamente aislado a la fase de evaluación final, lo que permite la medición de la capacidad de generalización del modelo para medir nuevos datos.

Para garantizar la alimentación adecuada del modelo de aprendizaje profundo, el conjunto de datos se organizó en tres subgrupos: entrenamiento, validación, prueba. Cada uno contiene imágenes clasificadas en cinco categorías: Galvánica, Uniforme, Picadura, Cavitación y Normal. Esta segmentación se desarrolló con práctica estándar en la capacitación automática monitoreada, que facilita tanto las cargas de datos automatizadas como su procesamiento. La siguiente tabla muestra de la distribución de las imágenes por clases. Del mismo modo la imagen esquematiza la estructura de la carpeta utilizada en Google Drive, que permitió integrar efectivamente conjuntos de datos en Google Colab.

CLASE	ENTRENAMIENTO	VALIDACIÓN	PRUEBA	TOTAL DE IMAGENES
Galvánica	179	58	68	305
Uniforme	133	29	57	219
Picadura	129	36	19	184
Cavitación	135	40	61	236
Normal	100	24	23	147
Total	676	187	228	1091

TABLA 19 BLOQUE DE CÓDIGO




ILUSTRACIÓN 2 DISTRIBUCIÓN DE DATASET

2.9 ENTRENAMIENTO DEL MODELO

El modelo presentado se fundamenta en la arquitectura VGG16 que ha sido previamente entrenada, elegida por su eficacia demostrada en actividades de visión computacional y su habilidad para identificar patrones visuales complejos y estructurados. A esta estructura se añadió el módulo de atención CBAM (Módulo de Atención por Bloque Convolutivo), el cual funciona secuencialmente prestando atención tanto por canales (estos representan un mapa de características) como al espacio (donde están ubicados los patrones), lo que permite al modelo enfocarse en las áreas importantes de la imagen y reducir el efecto del ruido de fondo. Este tipo de atención, tal como se menciona, “busca replicar la atención cognitiva” y potencia la habilidad del sistema para concentrar el aprendizaje en rasgos discriminativos esenciales.

Durante la etapa de entrenamiento se utilizó la técnica de transferencia de aprendizaje. En un inicio, las capas profundas convolucionales del modelo VGG16 se mantuvieron sin cambios para conservar el conocimiento previamente obtenido del conjunto de datos, lo que

ayuda a mejorar tanto la duración como la efectividad del proceso de entrenamiento. Posteriormente, las capas superiores se descongelaron con el fin de realizar un ajuste fino que permita adaptar el modelo al ámbito específico de la corrosión galvánica. La transferencia de aprendizaje facilita "la utilización de conocimientos existentes, desarrollados para la resolución de problemas de datos, para resolver nuevos problemas." (¿Qué es el Transfer Learning?, 2023)

Para aumentar la diversidad del conjunto de datos y evitar el sobreajuste, se llevaron a cabo estrategias de aumento de datos usando ImageDataGenerator, incorporando transformaciones como rotaciones de $\pm 20^\circ$, acercamientos de hasta un 15%, desplazamientos tanto horizontales como verticales, y cambios en el brillo. Estas estrategias imitan circunstancias reales de evaluación (variaciones en ángulo, luz y presencia de suciedad), mejorando la resiliencia del modelo frente a entornos industriales cambiantes.

Para optimizar el desempeño, se optó por el algoritmo Adam, el cual es conocido por su capacidad para ajustar la tasa de aprendizaje de forma adaptativa y constante, lo que propicia una convergencia más rápida y precisa. Del mismo modo, se añadieron los callbacks EarlyStopping y ReduceLROnPlateau, que hacen posible concluir el entrenamiento al detectar una falta de progreso y reducir la tasa de aprendizaje de manera dinámica si no se observan mejoras, evitando así el sobreajuste y mejorando el proceso.

El proceso de entrenamiento se llevó a cabo en Google Colab, el cual permite el uso de GPU, lo que hace más fácil y efectivo el manejo de grandes cantidades de imágenes y acelera los periodos de entrenamiento, todo esto sin requerir un equipo local de alta gama. Este entorno también favorece la reproducción de resultados y la oportunidad de modificar el modelo de forma colaborativa.

2.10 ANÁLISIS DE ERRORES DEL MODELO.

Durante el proceso de entrenamiento, se documentaron las gráficas de desarrollo de precisión y pérdida tanto para los conjuntos de entrenamiento como para los de validación. Tal y como se presenta en la ilustración 3, la exactitud del entrenamiento aumentó de manera gradual, comenzando en un 20 % y alcanzando cifras superiores al 95 %. La exactitud en la validación fue constantemente mayor en las fases iniciales y se mantuvo alrededor del 93 % hacia la época 60, mostrando ligeras variaciones en comparación con el conjunto de entrenamiento. Esto sugiere que el modelo no muestra señales claras de sobreajuste, lo cual evidencia una adecuada capacidad de generalización.




ILUSTRACIÓN 3 GRÁFICO ACCURACY

De igual manera, la ilustración 4 ilustra el desarrollo de la función de pérdida en las dos etapas. En los inicios, la pérdida era alta (superior a 3), pero disminuyó de manera continua hasta estabilizarse en valores por debajo de 0.1, tanto en el entrenamiento como en la validación. La disminución constante de la pérdida, sin diferencias significativas entre las dos curvas, demuestra que el proceso de aprendizaje fue exitoso, estable y correctamente optimizado utilizando el optimizador Adam.




ILUSTRACIÓN 4 GRÁFICO LOSS

El análisis de errores del modelo se llevó a cabo mediante la interpretación de la matriz de confusión, producida a partir del conjunto de datos de prueba. Esta herramienta estadística facilita la evaluación de la calidad del modelo, yendo más allá de la precisión general. Identifica los errores por categoría y determina los patrones de confusión entre tipos concretos de corrosión.

La matriz obtenida a partir del conjunto de prueba mostró un rendimiento muy positivo en las clases de cavitación (100 %) y uniforme (97 %), mientras que las mayores confusiones ocurrieron en la clase galvánica, con un 88 % de respuestas correctas y un 12 % de errores distribuidos entre otras categorías. Específicamente, el modelo cometió errores al clasificar 3 imágenes de galvánica como corrosión uniforme, 2 como cavitación, 1 como picadura y 1 como superficie normal. De igual manera, se detectaron errores entre la picadura y la cavitación y entre la superficie normal y la galvánica, cavitación (consulte ilustración 18 y 19).




ILUSTRACIÓN 5 MATRIZ DE CONFUSIÓN

🔍 Análisis de confusión entre clases:

- ⚠️ Se confundieron 3 imagen(es) de 'GALVANICA' como 'UNIFORME'
- ⚠️ Se confundieron 1 imagen(es) de 'GALVANICA' como 'PICADURA'
- ⚠️ Se confundieron 2 imagen(es) de 'GALVANICA' como 'CAVITACION'
- ⚠️ Se confundieron 1 imagen(es) de 'GALVANICA' como 'NORMAL'
- ⚠️ Se confundieron 1 imagen(es) de 'UNIFORME' como 'PICADURA'
- ⚠️ Se confundieron 1 imagen(es) de 'PICADURA' como 'GALVANICA'
- ⚠️ Se confundieron 2 imagen(es) de 'PICADURA' como 'CAVITACION'
- ⚠️ Se confundieron 1 imagen(es) de 'NORMAL' como 'GALVANICA'
- ⚠️ Se confundieron 1 imagen(es) de 'NORMAL' como 'CAVITACION'

ILUSTRACIÓN 6 ANÁLISIS DE CONFUSIÓN

Estos errores se pueden atribuir, en su mayoría, a tres razones principales:

1. Similitudes visuales entre tipos de corrosión: La corrosión galvánica presenta rasgos visuales similares a la corrosión uniforme, en especial cuando la región de contacto entre metales no es claramente observable. Asimismo, la cavitación y la picadura muestran patrones específicos que son complicados de identificar en imágenes que carecen de profundidad y textura acentuada.

2. Desigualdad de clases: La cantidad de imágenes que hay para cada clase no es igual, lo que puede afectar el proceso de aprendizaje del modelo. Los modelos suelen favorecer a las clases más numerosas, disminuyendo la atención hacia las clases minoritarias.

3. Calidad de imagen variable: Alteraciones en la iluminación, el ángulo de toma y la resolución influyen en la identificación de características importantes, provocando variaciones en la clasificación. Esto se mostró en imágenes categorizadas como galvánica o normal en situaciones subóptimas.

Así, la matriz de confusión también posibilita el cálculo de métricas importantes como la precisión por clase, el recall y el F1-score, lo que ayuda a obtener una comprensión más detallada del rendimiento. Entender estos errores es fundamental para guiar mejoras futuras en el preprocesamiento de imágenes, el equilibrio del conjunto de datos y la estructura del modelo.

3. CAPÍTULO 3: EVALUACION DEL MODELO EN PRUEBAS DE CAMPO.

3.1 INTRODUCCIÓN A LA EVLUACIÓN DEL MODELO

La evaluación de un modelo de visión por computadora no se restringe solo a su rendimiento en fases de entrenamiento y validación controladas. Para evaluar su uso práctico en entornos industriales, es fundamental realizar pruebas en el campo que imiten las condiciones operativas en las cuales suceden los fenómenos que se pretende identificar.

En este estudio, se creó un modelo destinado a la detección automática de corrosión galvánica en metales, el cual fue entrenado con un conjunto de datos presentado en un entorno controlado. Se implementaron técnicas de compensación para mitigar el impacto de los desequilibrios entre las clases, incluyendo la generación de datos adicionales y la asignación de pesos de clase a lo largo del proceso de entrenamiento. No obstante, las estructuras metálicas que están bajo condiciones reales muestran una variabilidad significativa, relacionada con alteraciones en la luz natural, sombras, suciedad, acumulación de productos corrosivos, estados superficiales y formas complejas, lo que puede complicar la captura y el análisis de las fotografías.

Estas situaciones pueden afectar de manera directa la exactitud, el regreso y la consistencia de las predicciones, poniendo a prueba la habilidad del modelo para generalizar. Por lo tanto, la evaluación en el sitio es una etapa clave para verificar si el desempeño registrado en el laboratorio se puede sostener en condiciones reales y operativas.

Estudios previos han evidenciado que elementos ambientales y deterioros en la calidad de imagen tales como cambios en la iluminación, desenfoque y ruido provocan reducciones considerables en la precisión de los modelos de clasificación por visión computacional cuando se aplican en contextos no controlados (Pei, 2018). Este tipo de descubrimientos subraya la importancia de verificar los sistemas de detección en situaciones reales de funcionamiento industrial.

3.2 COMPARACIÓN ENTRE ENTRENAMIENTO Y PRUEBAS DE CAMPO

La fase de entrenamiento y validación del modelo se llevó a cabo en un ambiente controlado, empleando un conjunto de imágenes organizado y equilibrado, obtenido en condiciones uniformes de iluminación, enfoque y fondo. Esta configuración facilitó que el modelo lograra un desempeño ideal al minimizar la influencia de variables externas, centrando su atención exclusivamente en las características visuales inherentes a la corrosión galvánica y a los otros cuatro tipos de superficies evaluadas en el estudio: corrosión uniforme, cavitación, picaduras y superficies libres de corrosión.

En este entorno controlado, la estructura fundamentada en VGG16, unida a un bloque de atención CBAM, consiguió diferenciar con gran precisión entre las distintas categorías, aprovechando la claridad de las imágenes, la falta de contaminantes y la definición en los límites y áreas afectadas por la corrosión.

Por otro lado, las evaluaciones en el campo se realizaron en una localidad donde los objetos estaban al intemperie expuestas a humedad relativa, a neblina y a diversas condiciones ambientales. Estas circunstancias provocan alteraciones en la luz natural, la aparición de suciedad en la superficie, zonas con sombras y contornos irregulares que dificultan la obtención de imágenes claras. Estas diferencias reflejan las verdaderas condiciones de inspección, en las que el modelo podría ser empleado de forma práctica.

Con el propósito de evaluar el efecto de este cambio de contexto, se aplicaron las mismas métricas de rendimiento utilizadas en la validación en laboratorio precisión, recall, F1-score y exactitud general para medir de manera objetiva la variación entre los dos escenarios.

MÉTRICA	ENTRENAMIENTO/ VALIDACIÓN	PRUEBA DE CAMPO
Exactitud global(%)	92	67
F1- Score(Galvánica)	0.88	0.80
Precisión(Galvánica)	0.91	1.00
Recall(Galvánica)	0.84	0.67
Total de imágenes evaluadas	187	9

TABLA 20 RESULTADOS ADQUIRIDOS

Los resultados adquiridos durante la fase de pruebas en el campo muestran una reducción en el rendimiento del modelo en comparación con las métricas logradas durante las etapas de entrenamiento y validación controladas. En un entorno de laboratorio, se logró una precisión total del 92 % y un F1-score de 0,88 para la categoría de corrosión galvánica. Sin embargo, en situaciones reales, la precisión total se redujo al 67 % y el F1-score a 0,80.

Este comportamiento se debe, principalmente, a las particularidades del entorno en el que se desarrolla la toma de imágenes. Con condiciones que provocan degradaciones visuales que complican la obtención de características distintivas y, como resultado, elevan la probabilidad de cometer errores en la clasificación.

El valor de precisión de 1,00 sugiere que cuando el modelo etiquetó una imagen como corrosión galvánica, lo hizo de manera correcta dentro del conjunto analizado. No obstante, un recall de 0,67 revela que el modelo acertó en la identificación de 6 de las 9 imágenes que eran realmente corrosión galvánica, mientras que 3 fueron incorrectamente clasificadas en otras categorías. Estos hallazgos indican que el modelo no generó falsos positivos para la categoría galvánica en esta evaluación, pero mostró una capacidad restringida para reconocer todos los casos reales en situaciones no controladas..

3.3 JUSTIFICACIÓN Y OBJETIVOS DE LAS PRUEBAS DE CAMPO

La valoración de un modelo de visión por computadora no debe restringirse únicamente a su rendimiento en un entorno de entrenamiento y validación que esté bajo control. Aunque estas fases posibilitan una estimación del potencial de la arquitectura sugerida, no representan fielmente la conducta real del modelo ante las condiciones ambientales y operativas características de un entorno industrial.

En este escenario, las pruebas en el campo son necesarias como una fase fundamental para comprobar la habilidad de generalización del sistema automático para detectar corrosión galvánica. A diferencia de las imágenes del conjunto de datos de entrenamiento.

Estas variables pueden modificar significativamente las propiedades visuales de la corrosión, influyendo de manera directa en el rendimiento del modelo. La evaluación en el terreno, por lo tanto, facilita la medición objetiva de la solidez, la fiabilidad y la aplicabilidad en la práctica de la solución sugerida.

Asimismo, estas validaciones son esenciales para aplicaciones industriales auténticas, donde los sistemas de detección necesitan funcionar en entornos no regulados, garantizando una identificación precisa del fenómeno sin necesidad de condiciones óptimas de captura.

El propósito de la prueba de campo consistió en comprobar el rendimiento efectivo del modelo entrenado al implementarlo en imágenes recogidas en otro ambiente. Esta fase posibilitó analizar su eficacia en la identificación de corrosión galvánica bajo diferentes condiciones ambientales y factores que no se encuentran en el contexto de entrenamiento. Asimismo, se intentó determinar cómo estas condiciones afectan la precisión y el recall, estableciendo de este modo el grado de fiabilidad del sistema para su aplicación en inspecciones reales.

3.4 LIMITACIONES Y OPORTUNIDADES DE MEJORA

La implementación de modelos de inteligencia artificial para detectar la corrosión galvánica en ambientes industriales representa un avance significativo en el mantenimiento preventivo y la actualización de los procedimientos. Sin embargo, al aplicar el modelo en situaciones reales, surgen diversas limitaciones técnicas, operativas y estratégicas que necesitan un análisis detallado.

Desde una perspectiva técnica, el modelo vigente que emplea VGG16 y CBAM requiere numerosos recursos computacionales, debido a la elevada cantidad de parámetros que gestiona. Esto podría limitar su integración en sistemas de inspección autónoma que funcionan en tiempo real, como drones destinados a labores industriales o robots que se desplazan. En este contexto, se resalta la posibilidad de examinar arquitecturas más livianas y eficaces (como MobileNetV2 o EfficientNet), las cuales pueden proporcionar niveles adecuados de precisión mientras demandan menos recursos.

De igual manera, el modelo se fundamenta en un conjunto de datos que debe ser representativo y equilibrado. La calidad y diversidad de las imágenes son fundamentales para mejorar la capacidad de generalización. Se recomienda crear en el futuro una base de datos industrial colaborativa, la cual se alimentaría de imágenes reales de diferentes sectores (minería, petroquímica, marítimo), fomentando colaboraciones con empresas para optimizar el entrenamiento del modelo y ampliar su uso práctico.

Un elemento clave es la incorporación cultural y funcional de estas tecnologías en el sector industrial. A pesar de que la inteligencia artificial ofrece ventajas claras en cuanto a su efectividad y habilidad para brindar protección, su adopción podría encontrar dificultades a causa de la oposición al cambio y la necesidad de formar al personal de manera adecuada. Se recomienda implementar programas de capacitación continua y talleres prácticos que faciliten a los empleados involucrarse en el uso y la valoración de los resultados.

3.5 RESULTADOS DE LAS PRUEBAS DE CAMPO

,De acuerdo a lo ilustrado en la ilustración 7, la matriz de confusión para el conjunto de validación revela un buen rendimiento del modelo en un entorno controlado. Las categorías de corrosión uniforme y cavitación lograron un 100 % de aciertos, mientras que la corrosión por picaduras y las superficies normales registraron un 97 % y un 96 %, respectivamente. La mayor complicación se observó en la categoría de corrosión galvánica, donde se identificaron correctamente 50 de las 58 imágenes, lo que representa un 86 %. Las 8 imágenes que quedaron fueron mal clasificadas, con 2 confundidas con corrosión uniforme, 2 con corrosión por picadura y 4 con cavitación. Estos hallazgos demuestran que, incluso bajo condiciones de validación estrictas, la corrosión galvánica resulta más desafiante de distinguir en comparación con otras clases que poseen rasgos visuales similares.

Matriz de Confusión - Validación

		true label				
	GALVANICA	50 (0.86)	2 (0.03)	2 (0.03)	4 (0.07)	0 (0.00)
	UNIFORME	0 (0.00)	29 (1.00)	0 (0.00)	0 (0.00)	0 (0.00)
	PICADURA	0 (0.00)	0 (0.00)	35 (0.97)	1 (0.03)	0 (0.00)
	CAVITACION	0 (0.00)	0 (0.00)	0 (0.00)	40 (1.00)	0 (0.00)
	NORMAL	0 (0.00)	0 (0.00)	0 (0.00)	1 (0.04)	23 (0.96)
		predicted label				
		GALVANICA	UNIFORME	PICADURA	CAVITACION	NORMAL

ILUSTRACIÓN 7 MATRIZ DE CONFUSIÓN



ILUSTRACIÓN 8 PRUEBA DE CAMPO 1



ILUSTRACIÓN 9 PRUEBA DE CAMPO 2



ILUSTRACIÓN 10 PRUEBA DE CAMPO 3



ILUSTRACIÓN 11 PRUEBA DE CAMPO 4



ILUSTRACIÓN 12 PRUEBA DE CAMPO 5



ILUSTRACIÓN 13 PRUEBA DE CAMPO 6



ILUSTRACIÓN 14 PRUEBA DE CAMPO 7

Para añadir a la información adquirida a través de la matriz de confusión, en las ilustración 21 a 27 se muestran ejemplos de las imágenes empleadas en la prueba de campo. Estas imágenes fueron tomadas en un espacio al aire libre, concretamente en una casa con estructuras de metal que están expuestas a las condiciones del clima, lo que refleja una situación real con factores ambientales no regulados. La elección abarca tanto situaciones que fueron clasificadas de manera correcta como ejemplos donde ocurrieron fallos en la predicción, con la finalidad de mostrar de manera visual los elementos que afectaron el rendimiento del modelo.

La matriz de confusión reveló que los errores se centralizaron en tres situaciones, en las cuales las imágenes fueron incorrectamente clasificadas como cavitación. Estas imágenes presentaban detalles visuales complejos: irregularidades en la textura de la superficie, acumulación de humedad, intensas variaciones de luz y áreas con suciedad, elementos que influyeron en la habilidad del modelo para identificar adecuadamente el patrón galvánico.

A pesar de esta reducción en la sensibilidad (recall 0,67), el modelo logró conservar una precisión del 100 %, lo que significa que cada vez que pronosticó Galvánica, lo hizo de manera correcta. Este tipo de comportamiento es característico en modelos que han sido entrenados en condiciones uniformes y, posteriormente, se enfrentan a situaciones reales que son más complicadas. Estos resultados representan una fuente técnica importante que puede guiar las mejoras futuras en la estructura del modelo y en la formación del conjunto de datos de entrenamiento, con el objetivo de mejorar su resistencia ante deterioros visuales ambientales.

3.6 ITERACIONES FUTURAS Y PROYECCIÓN DE MEJORAS

El modelo desarrollado en este estudio representa un primer paso hacia la creación de sistemas inteligentes de monitoreo para la detección temprana de corrosión galvánica. Sin embargo, el avance constante en la industria y las verdaderas necesidades del mantenimiento industrial demandan un enfoque de mejora continua, tanto en el ámbito técnico como en el organizativo.

Una de las metas más relevantes es ampliar el modelo para reconocer varios tipos de corrosión, tales como corrosión por picadura, la corrosión uniforme y la corrosión por cavitación. La identificación de diferentes clases de daños permitiría que el sistema se transforme en una herramienta integral para la gestión de activos, capaz de brindar valor en sectores como la minería, la generación de electricidad, la infraestructura civil y la industria marítima, donde se presentan diversas formas de deterioro de manera simultánea.

Además, se sugiere explorar arquitecturas de redes neuronales que ofrezcan mayor eficiencia, tales como MobileNetV2 y EfficientNet. Estas estructuras, al ser más ligeras y eficaces, reducen la demanda de recursos computacionales y facilitan la aplicación del modelo en dispositivos integrados, como drones de monitoreo o robots móviles. Esto es particularmente significativo para las inspecciones en lugares de difícil acceso o en entornos riesgosos, donde un trabajador no podría desempeñarse de forma segura.

Un área significativa de mejora consiste en la utilización de tecnologías de captura multiespectral y térmica. Incluir cámaras que operen en rangos de luz infrarroja o ultravioleta, además del espectro visible, permitiría detectar fallas y procesos de corrosión que no se pueden ver a simple vista. Por ejemplo, en zonas con recubrimientos o con acumulación de sedimentos, la utilización conjunta de imágenes térmicas ayudaría a detectar cambios de temperatura inusuales que indican áreas que podrían estar en condiciones de debilidad.

En el área de la gestión, se sugiere crear una base de datos colaborativa e industrial donde varias empresas puedan contribuir con imágenes capturadas en el campo. Esto incrementaría la diversidad del conjunto de datos, optimizaría la capacidad del modelo para generalizar y fomentaría la colaboración entre distintos sectores. Un sistema colaborativo

también permitiría la actualización periódica del modelo, incluyendo nuevas condiciones y contextos de la industria.

Una proyección clave es el desarrollo de una interfaz de usuario que sea sencilla de utilizar y operativa, destinada a profesionales técnicos y al personal responsable del mantenimiento. Esta interfaz puede mostrar resultados de inspección en tiempo real, generar informes automáticos, comparar condiciones anteriores y enviar alertas preventivas. Finalmente, se subraya la oportunidad de vincular el modelo con plataformas industriales ya establecidas.

Esta integración posibilitaría que la inteligencia artificial no solo reconozca daños, sino que también active automáticamente alertas, organice intervenciones y emita órdenes de mantenimiento. Esta cooperación facilitaría el paso hacia ambientes inteligentes y completamente interconectados, alineándose con los objetivos de la industria 4.0. Asimismo, ayudaría a mejorar la disponibilidad de los recursos, la protección de los empleados y la eficacia general de la instalación.

3.7 IMPACTO DEL MODELO EN LA TOMA DE DECISIONES Y BENEFICIOS OPERACIONALES.

La evaluación del modelo posibilita examinar su impacto en la toma de decisiones en los procesos de mantenimiento industrial, especialmente en situaciones donde la corrosión galvánica constituye un riesgo continuo para la integridad de las estructuras metálicas. A diferencia de la inspección visual convencional, que se basa únicamente en la observación directa del inspector, el modelo sugerido presenta un respaldo objetivo y replicable para la detección temprana de señales de deterioro.

Desde la perspectiva de la toma de decisiones, la aplicación del modelo simplifica la organización de acciones de mantenimiento, ya que permite reconocer de manera clara áreas con mayor riesgo de sufrir corrosión galvánica. Esta habilidad es especialmente importante en los programas de mantenimiento predictivo, donde prever el daño posibilita organizar intervenciones correctivas antes de que ocurran fallas estructurales o paradas no planificadas.

De esta manera el modelo actúa como una herramienta de apoyo que contribuye a reducir la incertidumbre en la evaluación del estado de los componentes y mejorar la planificación de las actividades de mantenimiento.

De igual manera, la creación de registros visuales organizados a partir del modelo ayuda a reducir la subjetividad que está presente en la inspección manual. A diferencia de la evaluación tradicional, que se basa en gran medida en la experiencia del inspector y en las condiciones de observación del momento, el sistema automatizado facilita la comparación de imágenes en diferentes momentos, utilizando criterios estables. Esta representación visual mejora la confianza en el diagnóstico y apoya de manera técnica las decisiones sobre el mantenimiento, lo cual se ajusta a los principios de gestión de activos establecidos en la norma ISO 55000, que resalta la importancia de tomar decisiones fundamentadas en información objetiva y comprobable (ISO 55000 y Sistemas de Gestión de Activos: Guía Completa, s.f.)

Desde el punto de vista operacional, la adopción del modelo ofrece ventajas potenciales vinculadas a la mejora en el uso de los recursos. Al funcionar como un recurso de preclasificación visual, el sistema facilitaría la disminución de la cantidad de inspecciones manuales presenciales en áreas de bajo riesgo, dirigiendo el trabajo humano hacia zonas previamente señaladas como críticas. Esto significa que hay una reducción del tiempo dedicado a la inspección, especialmente en instalaciones grandes o de difícil acceso, donde el tiempo de traslado, el montaje de equipos y las medidas de seguridad constituyen una parte importante de la actividad.

Desde un punto de vista económico, aunque este estudio no incluye un análisis de costes exhaustivo, se pueden reconocer impactos indirectos significativos. La disminución de las horas de trabajo dedicadas a inspecciones habituales, la reducción en el uso de herramientas de acceso (como andamios, plataformas o trabajos en alturas) y la menor exposición del personal a entornos perjudiciales ayudan a optimizar los costos operativos y a mejorar las condiciones de seguridad en el trabajo.

Finalmente, es esencial resaltar que el modelo no tiene como objetivo sustituir la inspección visual convencional, sino más bien apoyarla. Su incorporación como recurso de asistencia técnica facilita el aumento de la eficacia en el proceso de inspección, potencia la imparcialidad del diagnóstico y apoya la organización del mantenimiento mediante información visual organizada. En este contexto, el modelo se presenta como una opción efectiva para mejorar los programas de mantenimiento predictivo en instalaciones industriales que enfrentan corrosión galvánica, apoyando así una administración más eficiente, segura y sostenible de los recursos.

3.8 CONCLUSIONES Y RECOMENDACIONES

El progreso de esta investigación permitió alcanzar el objetivo de crear e implementar un modelo de inspección que utiliza inteligencia artificial y visión computacional para identificar corrosión galvánica en estructuras metálicas de uso industrial, analizando tanto los principios normativos como los aspectos técnicos y operativos vinculados a su uso.

Primeramente, el estudio de las normativas internacionales, como NACE SP21412-2016/SSPC-CPC 1, ASTM G82-98 e ISO 9223/8044, proporcionó una base conceptual para entender el fenómeno de la corrosión galvánica, reconociendo sus condiciones de aparición, factores que la afectan y sus manifestaciones en ambientes industriales. Esta revisión también justificó la elección de un enfoque que se basa en la inspección visual, complementado por herramientas de inteligencia artificial, demostrando que los modelos de visión computacional son una opción adecuada para superar las limitaciones de la inspección tradicional, tales como la subjetividad, las variaciones en los criterios de evaluación y las restricciones operativas.

En este marco, fue posible implementar un modelo de aprendizaje profundo utilizando la arquitectura VGG16, enriquecido con un módulo de atención CBAM, que se entrenó con un conjunto de datos organizado en cinco categorías de condiciones superficiales: corrosión galvánica, corrosión uniforme, corrosión por picaduras, corrosión por cavitación y superficies sin corrosión. La utilización de técnicas como la transferencia de

aprendizaje y el aumento de datos optimizó el proceso de entrenamiento, mejorando la habilidad del modelo para reconocer patrones visuales complejos relacionados con los diversos tipos de corrosión.

La evaluación del modelo mostró un rendimiento satisfactorio en entornos controlados, logrando una precisión del 92% y un F1-score de 0,88 en la detección de corrosión galvánica. Sin embargo, al probar el sistema en condiciones reales, que incluían variaciones en la luz, presencia de suciedad, humedad y formas irregulares, se notó una reducción en la precisión global hasta un 67%, lo que revela las restricciones actuales del modelo en situaciones no controladas. El análisis de los errores evidenció que las confusiones más frecuentes se presentaron entre las clases de corrosión galvánica y cavitación, debido a similitudes en sus características visuales en ciertas circunstancias, así como a la influencia de factores externos que afectan la calidad de las imágenes.

A pesar de estas limitaciones, los resultados conseguidos demuestran que el modelo creado es viable desde un punto de vista técnico como una herramienta complementaria a la inspección visual convencional, lo que permite aumentar la objetividad y la repetibilidad en el proceso de evaluación. En este sentido, su uso en tareas de mantenimiento industrial podría facilitar la identificación temprana de áreas críticas, priorizando las intervenciones y respaldando la toma de decisiones en estrategias de mantenimiento basadas en la condición.

BIBLIOGRAFÍA

- ASTM, 2019, sección 4.1. (s.f.).
- ASTM, 2019. (s.f.).
- (ISO 8044:2020). (s.f.).
- ISO 8044:2020. (s.f.).
- HELLIER, C. (2013). *Handbook of Nondestructive Evaluation*. McGraw-Hill Education.
- ASTM. (2019). ASTM G82-98. ASTM International.
- ASTM. (2019). ASTM G82-98. ASTM International.
- NACE, S.-2.-C. 1. (s.f.). NACE SP21412-2016/SSPC-CPC 1.
- NACE, S.-2.-C. 1. (s.f.). NACE SP21412-2016/SSPC-CPC 1.
- Reddy, N. O. (2022). *Hybrid Model for Detection of Corrosion in Water Pipeline Images Using CNN and Comparing Accuracy with SVM*. Electrochemical Society.
- Fathy, A. A.-G.-K. (2023). *Deep Learning-Based Approach for Detecting and Classifying Corrosion in Ship Hulls Using UAV Imagery*. MDPI.
- Team, D. (abril de 2023). *¿Qué es el Transfer Learning?* Obtenido de DataScientest : <https://datascientest.com/es/que-es-el-transfer-learning>
- Redacción, I. (septiembre de 2023). *La Inteligencia Artificial en la gestión avanzada de la corrosión*. Obtenido de Inspenet: https://inspenet.com/articulo/la-ia-en-la-gestion-de-la-corrosion/?utm_source=chatgpt.com
- Valdes, G. (Febrero de 2019). *Llegó la hora de calcular el costo de la corrosión en Chile*. Obtenido de El Mostrador: https://www.elmostrador.cl/noticias/opinion/2019/02/08/llego-la-hora-de-calcular-el-costode-la-corrosion-en-chile/?utm_source=chatgpt.com
- México, Z. (Septiembre de 2023). *El costo real de la corrosión*. Obtenido de Zerust México Blog: https://www.zerust.mx/blog/2023/09/21/el-costoreal-de-la-corrosion/?utm_source=chatgpt.com
- Redacción, I. (Septiembre de 2023). *La Inteligencia Artificial en la gestión avanzada de la corrosión*. Obtenido de Inspenet: <https://inspenet.com/articulo/la-ia-en-la-gestion-de-la-corrosion/>
- Espinoza Llanos, J. A. (2024). *Modelo de clasificación de corrosión basado en Deep Learning*. Obtenido de Revista de Marina: https://revistamarina.cl/es/articulo/modelo-de-clasificacion-de-corrosion-basado-en-deep-learning?utm_source=chatgpt.com
- Alex Tomás, C. M. (2024). *El impacto de la inteligencia artificial en el mantenimiento industrial*. Obtenido de Fractal: https://www.fractal.com/es/blog/el-impacto-de-la-inteligencia-artificial-en-el-mantenimiento-industrial?utm_source=chatgpt.com
- Rodríguez, M. (2025). *NDT con IA: Automatización para la inspección industrial*. Obtenido de Inspenet: https://inspenet.com/articulo/ndt-con-ia-en-la-inspeccion-industrial/?utm_source=chatgpt.com
- Hellier, C. (2013). *Handbook of Nondestructive Evaluation*. McGraw-Hill Education.
- DataCamp. (2024). *Introducción a las redes neuronales convolucionales (CNN)*. Obtenido de DataCamp: https://www.datacamp.com/es/tutorial/introduction-to-convolutional-neural-networks-cnns?utm_source=chatgpt.com

- Ultralytics. (s.f.). *Explicación de ResNet*. Obtenido de Ultralytics:
https://www.educaopen.com/digital-lab/blog/inteligencia-artificial/resnet?utm_source=chatgpt.com
- GeeksforGeeks. (2023). *MobileNetV2 Architecture and Applications*. Obtenido de MobileNetV2 Architecture and Applications.:
https://www.geeksforgeeks.org/computer-vision/what-is-mobilenet-v2/?utm_source=chatgpt.com
- Pei, W. H. (OCTUBRE de 2018). *Effects of Image Degradations to CNN-based Image Classification*. Obtenido de arXiv: <https://arxiv.org/abs/1810.05552>
- ISO 55000 y Sistemas de Gestión de Activos: Guía Completa. (s.f.). Obtenido de EasyMaint: Software de Mantenimiento Industrial: <https://www.easy-maint.net/es/blog/iso-55000-y-sistemas-de-gestion-de-activos-guia-completa.html>