

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
SEDE VIÑA DEL MAR - JOSÉ MIGUEL CARRERA

DESARROLLO DE UN MODELO DE INSPECCIÓN DE UNIONES SOLDADAS
MEDIANTE INSPECCION VISUAL CON INTELIGENCIA ARTIFICIAL Y VISION
COMPUTACIONAL

Trabajo de Titulación para optar al Título de
Ingeniero en Mantenimiento Industrial

Alumno: Diego Ignacio Argomedo Toribio

Profesor Guía: Mg. Ing. Pablo Andrés Duque Ramírez

2024

DEDICATORIA

Este trabajo representa no solo el resultado de años de esfuerzo, perseverancia y dedicación, sino también es el reflejo del apoyo incondicional de las personas que han estado presentes en cada paso de este camino, alcanzar esta meta habría sido mucho más difícil, y es por eso por lo que quiero dedicarles este logro con todo mi cariño y gratitud.

A mis abuelos, Nemesio Toribio, Margarita Urrutia, Agustín Argomedeo y Amalia Brito, quienes con su amor, sabiduría y enseñanzas han sido una gran inspiración en mi vida. Sus valores y su cariño entregados han sido un pilar en mi vida, enseñándome la importancia del esfuerzo y la perseverancia.

A mi hermana, Camila Argomedeo, por ser una compañera de vida, un apoyo incondicional y por demostrarme lo que es fortaleza. Su confianza, alegría y presencia han sido una motivación día a día para no rendirme ante la adversidad.

A mi novia, Maura Cerda, un pilar fundamental en mi vida. Su amor incondicional, paciencia y compañía me han dado la fortaleza para afrontar cada desafío. En los momentos difíciles siempre estuviste a mi lado, alentándome y recordándome que soy capaz de todo. Tu apoyo a sido invaluable y tu presencia, esencial. No hay palabras suficientes para expresar lo importante que has sido para mí. Te amo

Y finalmente, con todo mi amor y gratitud, dedico este trabajo a mis padres, Aldo Argomedeo y Andrea Toribio, quienes han sido el mayor cimiento de cada uno de mis logros. Su sacrificio, dedicación y amor han sido la base de todo lo que logrado en mi vida. Desde el primer momento me brindaron todo lo necesario para crecer, aprender y avanzar en la vida, guiándome con su ejemplo y enseñándome el significado de perseverancia y esfuerzo. No hay palabras suficientes para agradecerles todo lo que han hecho por mí. Este logro es tanto mío como suyo, porque sin su apoyo, jamás habría llegado hasta aquí, Los amo con todo mi corazón

A ustedes, mi familia, gracias por todo. Este título es para ustedes.

RESUMEN

Keywords: Inteligencia artificial, visión computacional, inspección visual, redes neuronales convolucionales, normas AWS D1.1 e ISO 13018

Este proyecto se basa en el desarrollo de un modelo de inteligencia artificial basado en visión computacional para inspección visual de soldadura, con los criterios de la norma AWS D1.1 e ISO 13018, estas normas establecen los criterios de calidad de soldadura y los métodos correctos de inspección visual, la inspección visual tradicional, tiene una incertidumbre constante la cual es el factor humano, ya que la evaluación de una soldadura se rige por la experiencia del inspector y su criterio, además que al ser humano está sometido a fatiga lo cual puede afectar a la inspección, con esto se vio la oportunidad de mejora de automatizar este proceso dando un resultado más preciso y consistente.

Se implemento un modelo de redes neuronales convolucionales (CNN) desarrollado en PyTorch y entrenado con imágenes correspondientes a las categorías de soldadura de la norma AWS D1.1 los cuales son: Soldadura en buen estado, agrietamiento, porosidad, salpicadura y socavación. El proceso se basó en la recopilación de imágenes, procesamiento de estas y aumento del dataset, además de los ajustes de parámetros para aumentar su optimización. El modelo fue codificado mediante Google Colab y el almacenamiento vinculado a este fue mediante Google Drive, permitiendo una manipulación más sencilla del dataset.

El modelo fue sometido a pruebas de campo, pudiendo así evaluar su desempeño en situaciones reales, el modelo alcanzo una efectividad de un 87% dando un resultado aceptable en la detección de defectos, se detectaron ciertas limitaciones como la influencia de la iluminación, pero esto da oportunidad de mejora del proyecto. Estos resultados demuestran que una inspección visual de soldadura de forma automatizada con inteligencia artificial es un camino viable permitiendo una evaluación más neutral, eficiente y objetiva eliminando así el factor humano dándole mayor robustez a este proceso

INTRODUCCIÓN

En la industria contemporánea, la inspección de soldaduras en superficies tubulares y no tubulares es una actividad para proteger, tanto la seguridad como la eficiencia en los entornos industriales. Sin embargo, los métodos convencionales de inspección visual se encuentran limitados por su eficiencia, lo que conlleva a un aumento de incertidumbre y de costos operativos, impactando en la toma de decisiones estratégicas.

Para enfrentar estos desafíos, se plantea la integración de la inteligencia artificial, la visión por computadora mediante Inspección Visual en los sistemas de inspección de soldaduras. Esta sinergia tecnológica promete brindar una solución, capaz de analizar grandes volúmenes de datos visuales de manera eficiente. No obstante, la implementación de estas tecnologías se enfrenta a obstáculos como la adaptación a diversas condiciones ambientales y operativas, así como el cumplimiento de normativas específicas de calidad y seguridad.

En este contexto, el presente proyecto se orienta a desarrollar y validar un modelo de visión por computadora basado en inteligencia artificial e Inspección Visual, que se ajuste a los estándares de calidad y seguridad de la industria para la inspección de soldaduras en superficies tubulares y no tubulares. Se llevará a cabo un análisis de las normativas y modelos de inteligencia artificial existentes, seguido del desarrollo de un modelo de IA y visión por computadora adaptado a las necesidades específicas de la industria.

Posteriormente, se procederá a la realización de pruebas de campo para evaluar la funcionalidad del modelo, asegurando su capacidad para detectar de indicaciones en las soldaduras. De esta forma, se espera que este sistema integrado contribuya a mejorar la gestión del mantenimiento industrial

La implementación exitosa de este proyecto no solo fortalecerá la seguridad y eficiencia en las operaciones industriales, sino que también promoverá la innovación tecnológica en el ámbito de la inspección de soldaduras. Además, se reducirán los riesgos de accidentes laborales y se optimizarán los recursos en el mantenimiento preventivo. Esto generará beneficios económicos al minimizar los tiempos de inactividad de los equipos y mejorar la productividad general de las plantas industriales. En última instancia, este proyecto representa un paso significativo hacia la excelencia operativa y la sostenibilidad en el sector industrial.

INDICE

DEDICATORIA.....	2
RESUMEN 3	
INTRODUCCIÓN	4
INDICE 5	
TABLA DE ILUSTRACIONES	8
INDICE DE TABLA.....	9
INDICE DE DIAGRAMAS	9
SIGLAS 10	
TERMINOLOGIA	10
OBJETIVO GENERAL	11
OBJETIVOS ESPECÍFICOS	11
CAPÍTULO 1: ANÁLISIS Y DESCRIPCIÓN DE MODELO DE INTELIGENCIA ARTIFICIAL 12	
1.1. OPORTUNIDAD DE INTEGRAR TECNOLOGÍAS AVANZADAS DE INSPECCION VISUAL A UNIONES SOLDADAS	13
1.2. SELECCIÓN DE NORMAS AWS D1.1 – ISO 13018	14
1.2.1 ALCANCE.....	15
1.2.2 SOLDADURA EN BUEN ESTADO	15
1.2.3 DISCONTINUIDADES COMUNES DE SOLDADURA	17
1.2.4 CRITERIOS DE ACEPTACION DE INSPECCION VISUAL	19
1.3 INSPECCIÓN VISUAL	19
1.3.1 DEFINICIONES Y METODOS:	20
1.4 TÉCNICAS Y TECNOLOGÍA RELEVANTES PARA LA INSPECCIÓN DE SOLDADURAS CON INSPECCIÓN VISUAL	21
1.5 MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN	21
1.6 COMPARACIÓN DE ENFOQUES TRADICIONALES Y AVANZADOS.	22
1.6.1 Enfoque Tradicional.....	22

1.3.1	Enfoque Avanzado: Modelo Automatizado con IA.....	23
1.7	ANÁLISIS DE NORMAS Y TECNOLOGÍAS.....	24
CAPÍTULO 2: GENERACIÓN Y ALIMENTACIÓN DE LA INTELIGENCIA ARTIFICIAL		25
2.1	INTRODUCCIÓN AL DESARROLLO DE IA	26
2.1.1	GOOGLE COLAB Y GOOGLE DRIVE	28
2.2	RELACIÓN CON NORMAS DE INSPECCIÓN VISUAL.....	29
2.3	HERRAMIENTAS Y TECNOLOGÍAS UTILIZADAS EN EL DESARROLLO DEL MODELO.....	29
2.3.1	PYTORCH.....	29
2.3.2	MACHINE LEARNING.....	30
2.3.3	VISIÓN COMPUTACIONAL.....	30
2.4	SINERGIA ENTRE MACHINE LEARNING Y VISIÓN COMPUTACIONAL PARA EL MODELO.....	31
2.5	ARQUITECTURA DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	32
2.5.1	CAPAS CONVOLUCIONALES.....	32
2.5.2	CAPAS DE MAXPOOLING.....	32
2.5.3	CAPAS DROPOUT	33
2.5.4	FUNCIÓN RELU Y SOFTMAX.....	34
2.5.5	CONFIGURACIÓN DE HIPERPARÁMETROS	34
2.5.6	IMPACTO DE LOS HIPERPARAMETROS AL MODELO	35
2.6	PROCESAMIENTO DE IMÁGENES Y AUMENTO DE DATOS	36
2.6.1	PREPROCESAMIENTO	36
2.6.2	PREPARACIÓN DE DATASET Y ESTRUCTURA DE CARPETA.....	37
2.6.3	AUMENTO DE DATOS: ZOOM, ROTACIÓN Y DESPLAZAMIENTO DE IMÁGENES	39
2.6.4	IMÁGENES EN ESCALA DE GRISES	40
2.6.5	EFFECTO ESPEJO	44
2.6.6	RESUMEN: RELACIÓN DEL PROCESAMIENTO Y PREPARACIÓN DEL DATASET CON EL MODELO	45
2.7	EVALUACIÓN DEL DESEMPEÑO	46
2.7.1	MÉTRICAS DE EVALUACIÓN	46

2.8	LIMITACIÓN DEL MODELO	48
2.9	OPTIMIZACIÓN Y MEJORA DEL MODELO.....	49
2.10	RESULTADOS DE LAS PRUEBAS PRELIMINARES	50
2.10.1	DESEMPEÑO GLOBAL DEL MODELO.....	50
2.11	ANÁLISIS POR CATEGORÍAS:	51
2.11.1	CASO DE SOLDADURA EN BUEN ESTADO	53
2.11.2	CASO DE AGRIETAMIENTO.....	54
2.11.3	CASO DE POROSIDAD.....	54
2.11.4	CASO DE SALPICADURA.....	55
2.11.5	CASO DE SOCAVACIÓN.....	55
2.12	ANÁLISIS DE ERRORES EN DETECCIÓN DE ANOMALIAS	56
2.13	ANÁLISIS DE LA GENERACIÓN DEL MODELO DE IA.....	58
CAPITULO 3: EVALUACIÓN Y VALIDACIÓN DEL MODELO DE INSPECCIÓN VISUAL DE SOLDADURAS.....		59
3.8	INTRODUCCIÓN A LA EVALUACIÓN DEL MODELO	60
3.2	METODOLOGÍA DE EVALUACIÓN	61
3.4	ENFOQUE GENERAL	61
3.13	PRUEBAS DE CAMPO.....	62
3.5	EVALUACIÓN DEL MODELO MEDIANTE PRUEBAS DE CAMPO	63
3.6	ANÁLISIS DE LOS RESULTADOS DE LA PRUEBA DE CAMPO	71
3.7	LIMITACIONES DETECTADAS EN LA PRUEBA DE CAMPO	72
3.8	PROPUESTA DE MEJORA PARA LAS LIMITACIONES DEL MODELO	
73		
3.9	REFLEXIÓN FINAL DE LAS PRUEBAS DE CAMPO	74
CONCLUSIÓN		75
BIBLIOGRAFIA.....		76
ANEXOS		77

TABLA DE ILUSTRACIONES

Ilustración 1- Soldadura en buen estado 1	16
Ilustración 2- Soldadura Porosidad	17
Ilustración 3- Soldadura Agrietamiento	17
Ilustración 4- Soldadura Salpicadura	18
Ilustración 5- Soldadura Socavado.....	18
Ilustración 6- Criterios de aceptacion VT	¡Error! Marcador no definido.
Ilustración 7- Inspección Visual Tradicional	20
Ilustración 8- Codigo Google Drive.....	28
Ilustración 9- Codigo Torch	29
Ilustración 10- Codigo MaxPooling.....	32
Ilustración 11- Código DropOut	33
Ilustración 12- Codigo Relu y SoftMax	34
Ilustración 13- Configuración de Hiperparametros.....	35
Ilustración 14- Épocas de entrenamiento	35
Ilustración 15- Carpetas de Defectos	37
Ilustración 16- Configuración de imágenes	38
Ilustración 17- Configuración de Carpetas	38
Ilustración 18- Codigo Aumento de Dataset.....	39
Ilustración 19- Imagen original.....	40
Ilustración 20- Imagen original en escala de grises	41
Ilustración 21- Imágenes Convertidas en escala de grises	41
Ilustración 22- Épocas.....	42
Ilustración 23- Grafica entrenamiento escala de grises.....	42
Ilustración 24- Detección Correcta de estado de soldadura	43
Ilustración 25-Matriz de confusión inicial	43
Ilustración 26-Grafica Efecto espejo.....	44
Ilustración 27- Entrenamiento Efecto espejo	44
Ilustración 28- Ajuste Hiperparametros	45
Ilustración 29- Matriz de confusión	47
Ilustración 30- Soldadura con Poros internos	48
Ilustración 31- Detección de soldaduras en buen estado	49
Ilustración 32- Matriz de confusión final.....	50
Ilustración 33- Precisión soldadura en buen estado	51
Ilustración 34- Precisión Agrietamiento	51
Ilustración 35- Precisión Porosidad	52
Ilustración 36- Precisión Salpicadura.....	52

Ilustración 37- Presición Socavación	53
Ilustración 38- Caso Soldadura en buen estado	53
Ilustración 39- Caso Agrietamiento	54
Ilustración 40- Caso Porosidad	54
Ilustración 41- Caso Salpicadura	55
Ilustración 42- Caso Socavación	55
Ilustración 43- Prueba de campo nr.1 - Soldadura en buen estado	63
Ilustración 44- Análisis del modelo de Prueba de campo Nr. 1	63
Ilustración 45- Prueba de campo Nr.2 – Porosidad.....	64
Ilustración 46- Análisis del modelo de Prueba de campo Nr.2.....	64
Ilustración 47- Prueba de campo Nr 3. Porosidad.....	65
Ilustración 48- Analisis del modelo de Prueba de Campo Nr. 3	65
Ilustración 49- Prueba de campo Nr. 4 Porosidad.....	66
Ilustración 50- Analisis del modelo de Prueba de Campo Nr. 4	66
Ilustración 51- Prueba de campo Nr. 5 Socavación	67
Ilustración 52- Análisis del modelo de Prueba de Campo Nr. 5	67
Ilustración 53- Prueba de campo Nr.6 Agrietamiento	68
Ilustración 54- Análisis del modelo de Prueba de Campo Nr. 6	68
Ilustración 55- Prueba de campo Nr.7 Salpicadura.....	69
Ilustración 56- Análisis del modelo de Prueba de Campo Nr. 7	69
Ilustración 57- Prueba de campo Nro 8 Agrietamiento	70
Ilustración 58- Anexo 1 % precisión.....	77
Ilustración 59- Anexo 2 Paquete perdida	77

INDICE DE TABLA

Tabla 1- Criterios de aceptación Fuente: AWS D1.1	19
Tabla 2- Método Tradicional VS método automatizado Fuente: Elaboración propia	¡Error! Marcador no definido.
Tabla 3- Distribución de imágenes en carpetas Fuente: Elaboración propia	38

INDICE DE DIAGRAMAS

Diagramas 1- Proceso de creación y validación del modelo.....	27
---	----

SIGLAS

1. **AI** - Artificial Intelligence (Inteligencia Artificial)
2. **CNN** - Convolutional Neural Network (Red Neuronal Convolucional)
3. **AWS** - American Welding Society (Sociedad Americana de Soldadura)
4. **ISO** - International Organization for Standardization (Organización Internacional de Normalización)
5. **VT** - Visual Testing (Inspección Visual)
6. **SSPC** - Society for Protective Coatings (Sociedad para Recubrimientos Protectores)
7. **IA** - Inteligencia Artificial
8. **GPU** - Graphics Processing Unit (Unidad de Procesamiento Gráfico)
9. **CPU** - Central Processing Unit (Unidad Central de Procesamiento)
10. **F1-score** - Medida de precisión en clasificación (combinación de precisión y recall)

TERMINOLOGIA

Inspección visual (VT – Visual Testing): Método de evaluación de soldaduras de forma óptica directamente a identificar discontinuidades

Red neuronal convolucional (CNN): Modelo de IA utilizado en visión computacional para clasificación de imágenes

Inteligencia artificial (IA): Rama informática que desarrolla sistemas de tareas que pueden realizarse con inteligencia humana

Discontinuidad: Irregularidad o imperfección en una soldadura que puede afectar a su integridad estructural

Hiperparámetro: parámetro configurable en un modelo de aprendizaje automático que influye en su desempeño y entrenamiento

OBJETIVO GENERAL

Desarrollar un sistema automatizado de inspección de soldaduras en superficies tubulares y no tubulares, con inteligencia artificial e Inspección Visual detectando y clasificando discontinuidades en soldaduras, cumpliendo con los estándares de calidad internacionales.

OBJETIVOS ESPECÍFICOS

- Analizar las normas internacionales de Inspección visual y soldadura, identificando las técnicas y tecnologías relevantes para el desarrollo del modelo de inteligencia artificial y visión computacional.
- Generar el modelo de Inteligencia Artificial y Visión Computacional, utilizando herramientas de procesamiento de imágenes y técnicas de aprendizaje automático para el sistema de inspección de soldaduras considerando las normas de Inspección Visual.
- Evaluar la funcionalidad del modelo mediante pruebas de campo determinando el éxito de la evaluación ejecutada mediante la metodología de inspección visual, validando la efectividad del modelo de detección.

CAPÍTULO 1: **ANÁLISIS Y DESCRIPCIÓN DE MODELO DE INTELIGENCIA**
ARTIFICIAL

1.1. OPORTUNIDAD DE INTEGRAR TECNOLOGÍAS AVANZADAS DE INSPECCION VISUAL A UNIONES SOLDADAS

La incorporación de Inteligencia artificial (IA) y la visión computacional en la inspección de soldadura es una oportunidad para mejorar la precisión y la eficiencia en el proceso de inspección de soldadura, los métodos tradicionales son muy utilizados en la industria, pero tienen ciertas limitaciones debido a la subjetividad del inspector y la fatiga visual que puede tener, lo que puede generar incertidumbre en la detección debido al factor humano.

Mediante el uso de IA y visión computacional, es posible que se pueda analizar en una gran cantidad de imágenes de manera más rápida y sin limitaciones humanas, este modelo permite una clasificación más objetiva de las discontinuidades, reduciendo la dependencia de la experiencia que posea el inspector

Además de mejorar la calidad de las inspecciones, los modelos de IA pueden utilizarse en tiempo real, lo que entrega una respuesta inmediata de los problemas detectados y así minimizar los tiempos de inactividad y mejorar la eficiencia operativa, la implementación del modelo tanto las superficies planas como tubulares ayudara a minimizar los riesgos a defectos estructurales.

1.2. SELECCIÓN DE NORMAS AWS D1.1 – ISO 13018

La inspección visual es un método que garantiza una buena calidad estructural en una unión soldada y detectar a tiempo posibles discontinuidades, para poder darle un enfoque preciso y acorde a los estándares internacionales, se basara en normativas reconocidas tanto nacionalmente como internacionalmente, definiendo criterios y metodologías adecuadas para la inspección visual

La ISO 13018 es ideal para la inspección visual de soldaduras debido a su enfoque en esta técnica, proporciona criterios y procedimiento de inspección que garantiza calidad y seguridad de las soldaduras. A diferencia de otras normas más generales como puede ser la ISO 17637 o la ISO 5817, en cambio la ISO 13018 está especializada en métodos de inspección visual lo que la hace más adecuada para identificar defectos sin necesidad de equipos altamente tecnológicos

La elección de la norma AWS D1.1 sobre otras normas como la AWS D1.2, AWS D1.3, AWS D1.5, AWS D1.6, AWS D1.8, ASME sección IX, ISO 5817, se basó en que la AWS D1.1 tiene una gran capacidad ya que reconoce una gran cantidad de aceros, lo cual es perfecto para este proyecto

La AWS D1.1 es reconocida en la industria ya que establece estándares de calidad y seguridad en todo proceso de soldadura, ha sido muy importante en este proyecto ya que el propósito de esta norma de alinea con la metodología utilizada nen este proyecto, dando los mejores estándares a nivel internacional, así de esta forma garantizar una integridad estructural

1.2.1 ALCANCE

Este trabajo desarrolla dentro de los requerimientos de la norma AWS D1.1, lo cual define los criterios para el diseño, inspección y evaluación de uniones soldadas en estructuras tanto tubulares como no tubulares

“Esta sección cubre los requerimientos para el diseño de conexiones soldadas. Está dividida en cuatro partes:

Parte A-Requerimientos Comunes para el Diseño de Conexiones Soldadas (Miembros No Tubulares y Tubulares).

Parte B-Requerimientos Específicos para el Diseño de Conexiones No Tubulares (Cargadas Estática o Cíclicamente). Los requerimientos deben aplicar en adición a los requerimientos de la parte A.

Parte C-Requerimientos Específicos para el Diseño de Conexiones No Tubulares (Cargadas Cíclicamente). Cuando sea aplicable, los requerimientos deben aplicar en adición a los requerimientos de las partes A y B.

Parte D-Requerimientos Específicos para el Diseño de Estructuras Tubulares (Cargadas Estáticamente y Cíclica- mente). Cuando sea aplicable, los requerimientos deben aplicar en adición a los requerimientos de la parte A.”

(American Welding Society (AWS) D1.1, 2020)

1.2.2 SOLDADURA EN BUEN ESTADO

Una soldadura en buen estado se basa al tener una superficie lisa libre de imperfecciones

- Que tenga una buena fusión entre el electrodo y el metal base
- Una penetración completa, asegurando que la soldadura recorra todo el espesor del material base
- Ausencia de Poros, grietas u otras discontinuidades
- Un buen perfil, sin socavación, bordes afilados, ni deformaciones

En la soldadura, es de suma importancia seguir con las especificaciones de la normativa, lo cual asegura calidad en las uniones, tanto para soldaduras en flete, uniones T , tubulares. Hay ciertos criterios que se deben detallar para garantizar una buena ejecución.

“Para soldaduras de filete y juntas en T oblicuas, en los documentos del contrato debe proporcionarse lo siguiente:

(1) Para soldaduras de filete entre partes con superficies que coinciden en un ángulo de entre 80° y 100°, los documentos del contrato deben especificar el tamaño de la pierna de la soldadura de filete.

(2) Para soldaduras entre partes con superficies coincidentes en un ángulo menor a 80° o mayor a 100°, los documentos del contrato deben especificar la garganta efectiva.

De ser requeridos por diseño, los retornos finales y las contenciones para soldaduras de filete deben indicarse en los documentos del contrato.”



Ilustración 1- Soldadura en buen estado 1

Fuente: Shutterstock

W

(American Welding Society (AWS) D1.1, 2020)

1.2.3 DISCONTINUIDADES COMUNES DE SOLDADURA

Porosidades: Cavidades a lo largo de la soldadura causada por el atrapamiento de gases en el proceso de solidificación del electrodo.



Ilustración 2- Soldadura Porosidad
Fuente: Shutterstock

Grietas: fisuras a lo de la soldadura que puede ocurrir durante o después del proceso, debido a tensiones que sufra la soldadura



Ilustración 3- Soldadura Agrietamiento
Fuente: Google imágenes

Salpicadura: pequeñas partículas de electrodo fundido que se desprenden por el metal base



Ilustración 4- Soldadura Salpicadura

Fuente: Shutterstock

Socavado: mordeduras en el borde de la soldadura causado por técnica de soldadura incorrecta



Ilustración 5- Soldadura Socavado

Fuente: Shutterstock

Estos defectos pueden comprometen la integridad estructural y la capacidad de carga de estructuras soldadas, por lo tanto, es de suma importancia identificarlos y corregirlos

1.2.4 CRITERIOS DE ACEPTACION DE INSPECCION VISUAL

En este apartado veremos los criterios de aceptación de una soldadura mediante una inspección visual, reconociendo los defectos que pueda presentar una soldadura

Table 8.1
Visual Inspection Acceptance Criteria (see 8.9)

Discontinuity Category and Inspection Criteria	Statically Loaded Nontubular Connections	Cyclically Loaded Nontubular Connections
(1) Crack Prohibition Any crack shall be unacceptable, regardless of size or location.	X	X
(2) Weld/Base Metal Fusion Complete fusion shall exist between adjacent layers of weld metal and between weld metal and base metal.	X	X
(3) Crater Cross Section All craters shall be filled to provide the specified weld size, except for the ends of intermittent fillet welds outside of their effective length.	X	X
(4) Weld Profiles Weld profiles shall be in conformance with 7.23.	X	X
(5) Time of Inspection Visual inspection of welds in all steels may begin immediately after the completed welds have cooled to ambient temperature. Acceptance criteria for ASTM A514, A517, and A709 Grade HPS 100W [HPS 690W] steels shall be based on visual inspection performed not less than 48 hours after completion of the weld.	X	X
(6) Undersized Welds The size of a fillet weld in any continuous weld may be less than the specified nominal size (L) without correction by the following amounts (U): L, specified nominal weld size, in [mm] ≤ 3/16 [5] 1/4 [6] ≥ 5/16 [8] U, allowable decrease from L, in [mm] ≤ 1/16 [2] ≤ 3/32 [2.5] ≤ 1/8 [3] In all cases, the undersize portion of the weld shall not exceed 10% of the weld length. On web-to-flange welds on girders, under-run shall be prohibited at the ends for a length equal to twice the width of the flange.	X	X
(7) Undercut (A) For material less than 1 in [25 mm] thick, undercut shall not exceed 1/32 in [1 mm], with the following exception: undercut shall not exceed 1/16 in [2 mm] for any accumulated length up to 2 in [50 mm] in any 12 in [300 mm]. For material equal to or greater than 1 in [25 mm] thick, undercut shall not exceed 1/16 in [2 mm] for any length of weld. (B) In primary members, undercut shall be no more than 0.01 in [0.25 mm] deep when the weld is transverse to tensile stress under any design loading condition. Undercut shall be no more than 1/32 in [1 mm] deep for all other cases.	X	X
(8) Porosity (A) CJP groove welds in butt joints transverse to the direction of computed tensile stress shall have no visible piping porosity. For all other groove welds and for fillet welds, the sum of the visible piping porosity 1/32 in [1 mm] or greater in diameter shall not exceed 3/8 in [10 mm] in any linear inch of weld and shall not exceed 3/4 in [20 mm] in any 12 in [300 mm] length of weld. (B) The frequency of piping porosity in fillet welds shall not exceed one in each 4 in [100 mm] of weld length and the maximum diameter shall not exceed 3/32 in [2.5 mm]. Exception: for fillet welds connecting stiffeners to web, the sum of the diameters of piping porosity shall not exceed 3/8 in [10 mm] in any linear inch of weld and shall not exceed 3/4 in [20 mm] in any 12 in [300 mm] length of weld. (C) CJP groove welds in butt joints transverse to the direction of computed tensile stress shall have no piping porosity. For all other groove welds, the frequency of piping porosity shall not exceed one in 4 in [100 mm] of length and the maximum diameter shall not exceed 3/32 in [2.5 mm].	X	X

Note: An "X" indicates applicability for the connection type; a shaded area indicates non-applicability.

Note: An "X" indicates applicability for the connection type; a shaded area indicates non-applicability.

Tabla 1- Criterios de aceptación
Fuente: AWS D1.1

(American Welding Society (AWS) D1.1, 2020, pág. 239)

1.3 INSPECCIÓN VISUAL

En este apartado se hablará de la técnica de inspección visual, la cual es un análisis inmediato de forma óptica sobre algún objeto para determinar su condición

1.3.1 DEFINICIONES Y METODOS:

“Inspección Visual Directa: inspección óptica directamente desde el ojo hacia el area de prueba, puede ser asistida por espejo, lentes o fibras ópticas

Inspección Visual Remota: Uso de ayudas visuales tecnológicas como sistemas de video o robots

(BS EN ISO 13018, 2016)

En este proyecto se implementará un modelo de inteligencia artificial y visión computacional, por lo tanto, se utilizará inspección visual remota para la inspección de discontinuidades en soldaduras.

“Condiciones de Iluminación: Según el estándar a usar intensidad de luz debe estar entre 1100~ 3200 [Lux] en la superficie de la pieza (ASME V) o 160 [lux] ambiental y 850 [Lux] en la superficie a inspeccionar

Distancia: La distancia entre la superficie y el ojo debe estar entre 250 ~ 600 [mm] y con un ángulo mayor a 30°.”



Ilustración 6- Inspección Visual Tradicional
Fuente: Apunte IV PT MT Pablo Duque

(IV PT MT, Inspección y control 2021, Pablo Duque)

1.4 TÉCNICAS Y TECNOLOGÍA RELEVANTES PARA LA INSPECCIÓN DE SOLDADURAS CON INSPECCIÓN VISUAL

Crear un modelo para revisar soldaduras con IA y Vision computacional es unir varias ideas. La visión computacional ayuda a tomar y ver fotos de las soldaduras, encontrando errores. Estos sistemas pueden ver fotos al instante, lo que ayuda a notar rápido cualquier problema.

El uso de machine learning complementa las tecnologías lo cual permite que el modelo aprenda continuamente a base de grandes cantidades de imágenes recopilados durante la inspección. Algoritmos de aprendizaje supervisado y no supervisado son aplicados para reconocer patrones complejos y poder clasificar defectos con precisión. Esta capacidad de autoaprendizaje y adaptación constante hace que el modelo evolucione y mejore con el tiempo, incrementando así su efectividad y reduciendo errores humanos. La visión computacional y machine learning es una solución para el factor humano en inspecciones de soldaduras poco eficientes, mejorando la calidad y seguridad de fabricación en la industria

En el contexto del mantenimiento industrial, la visión computacional es útil en la identificación visual de los defectos que pueda presentar una soldadura, además de convertirse en una herramienta de análisis automatizado. Esto permite implementar soluciones inteligentes reduciendo la probabilidad de errores humanos. Según estudios la implementación de la visión computacional cambiara radicalmente las inspecciones, dando predicciones y decisiones más precisas y rápidas (Labeller,2024)

1.5 MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN

Las redes neuronales convolucionales (CNN) son efectivas en el proceso de imágenes. Estas redes clasifican los defectos gracias a sus capas convolucionales, ya que extraen las características de los defectos de una soldadura y las clasifica por categorías, dando así ideales para ser identificados según corresponda

Por otro lado, las Maquinas de soporte vectorial (SVM) pueden clasificar datos en múltiples dimensiones. Funcionan bien cuando las clases de defectos están bien definidas, SVM es especialmente útil en la identificación de imágenes de soldadura en buen estado y con algún defecto

La matriz de confusión es una herramienta para evaluar el rendimiento del modelo, este modelo permite evaluar el rendimiento del modelo de IA permitiendo comparar predicciones realizadas con los resultados, la matriz de confusión es útil ya que proporciona métricas clave, incluyendo la exactitud de eficacia de predicción por el total de casos evaluados

(MathWorks. (s.f.).)

1.6 COMPARACIÓN DE ENFOQUES TRADICIONALES Y AVANZADOS

La inspección visual de soldaduras es un método utilizado en la industria para clasificar el estado de una soldadura, tradicionalmente es realizado por inspectores, este método es efectivo, pero está sometido a las limitaciones humanas del inspector, con el avance de la tecnología, la implementación de la automatización está cada vez más presente, lo cual da la posibilidad de todas las limitaciones que pueda presentar el inspector ya no sea un problema

1.6.1 Enfoque Tradicional

Los métodos tradicionales de inspección visual dependen netamente de la experiencia y habilidad del inspector a cargo, este proceso está sometido a condiciones de iluminación, distancia y ángulos que estima la ISO 13018 y es bastante eficaz para detectar las discontinuidades que pueda presentar una soldadura.

Sin embargo, puede haber ciertas desventajas:

Subjetividad: Las evaluaciones pueden variar según el inspector

Fatiga Humana: Inspeccionar gran cantidad de soldaduras puede fatigar la vista del inspector

Limitaciones de Escalabilidad: Mientras la producción aumenta la capacidad para hacer inspecciones visuales se ve limitada según el tiempo

Falta de Datos Reutilizables: Generalmente la inspección de soldaduras no queda un histórico o datos estructurados por lo tanto no da a lugar a realizar un análisis para así mejorar los procesos.

1.3.1 Enfoque Avanzado: Modelo Automatizado con IA

El modelo automatizado de este proyecto basado en CNN y visión computacional aborda las limitaciones humanas previas neutralizándolas. Este modelo utiliza un sistema de aprendizaje el cual analiza y clasifica las discontinuidades que contenga una soldadura.

Entre las ventajas del enfoque avanzado se encuentran:

Consistencia y Objetividad: Al eliminar el factor humano, las predicciones son consistentes y objetivas

Capacidad de Escalamiento: el modelo será capaz de analizar una gran de imágenes

Generación de Datos Estructurados: Cada inspección genera datos para ser analizados y utilizados para optimizar los procesos

Capacidad de Mejora Continua: Mientras se vayan agregando inspecciones el modelo podrá aprender, mejorando así continuamente

ASPECTO	METODO TRADICIONAL	MODELO AUTOMATIZADO
Subjetividad	Alta, depende del inspector	Nula, basado en patrones predefinidos
Escalabilidad	Limitada por recursos humanos	Alta, puede manejar altos volúmenes de datos
Precisión	Variable según condiciones y experiencia	Consistente y basado en datos
Generación de datos	No estructurados, difícil de analizar	Estructurados, reutilizables
Cumplimiento de las normas	Depende de la interpretación del inspector	Integrado en el diseño del modelo

Tabla 2- Método Tradicional VS Modelo Automatizado

Fuente: Elaboración propia

1.7 ANÁLISIS DE NORMAS Y TECNOLOGÍAS

La Elaboración de este capítulo se basó en la selección de las normas a utilizar para el modelo de inteligencia artificial, las cuales son la AWS D1.1 y la ISO 13018, ya que estas proporcionan técnicas y criterios de aceptación de inspección visual adecuadas para este proyecto.

La norma AWS D1.1 utilizada para la inspección y certificación de soldaduras, fue electa debido a su amplio alcance de evaluación proporcionando claros estándares de aceptación para las soldaduras, por otro lado, la ISO 13018, la cual está especializada para inspección visual, fue escogida por su enfoque en métodos de inspección, al combinar estas dos normas permitió establecer un marco técnico sólido para el desarrollo del modelo, asegurando que la aplicación sea viable en la industria

Además del análisis normativo, también se analizaron y seleccionaron técnicas de visión computacional y machine learning para desarrollar un modelo capaz de detectar y clasificar discontinuidades en soldaduras de manera automatizada. Se optó por el uso de CNN y pytorch debido a su gran capacidad para extraer características en las discontinuidades para lograr hacer una clasificación eficaz de las mismas.

También la implementación de Google colab en colaboración con Google drive que será una vía de almacenamiento y de procesamiento el cual será bastante efectivo debido a su comodidad para trabajar

Para concluir, el análisis de las normas permitió establecer criterios de evaluación de forma clara para una buena inspección visual, la integración de visión computacional y machine learning entregará la automatización de la misma de la inspección, desarrollando un modelo el cual se espera que sea efectivo a la hora de mejorar la precisión y toma de decisión en la discontinuidad o el estado de la soldadura, con esto se logró cumplir con el objetivo específico número uno, dando las bases técnicas normativas y las tecnologías necesarias para la implementación del modelo.

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

2.1 INTRODUCCIÓN AL DESARROLLO DE IA


En este capítulo se describe el proceso de desarrollo del modelo de inteligencia artificial, abordando tecnologías, etapas y métodos necesarios para poder lograr una implementación. El principal propósito del modelo es identificar y clasificar en la discontinuidad que corresponda: Agrietamiento, Porosidad, Salpicadura y Socavación, si no se considerara soldadura en buen estado, todo esto alineado con la normativa AWS D1.1

El modelo está diseñado con redes neuronales convolucionales (CNN), una técnica ampliamente utilizada en visión computacional, ya que posee la capacidad de extraer características importantes en imágenes. Además, se utilizará Google Colab como entorno de programación y Google Drive como almacenamiento de datos. Todas estas herramientas dieron la capacidad de manejar las etapas de testeo, entrenamiento y validación del modelo

Se explican las técnicas de procesamiento y aumento de datos de imágenes para preparar el modelo, tanto, así como los ajustes del modelo durante el entrenamiento, hasta dar con el resultado obtenido y sus respectivas limitaciones para en algún futuro ser corregidas.

Este Capítulo es importante para entender cómo se integraron las tecnologías y que son, y como así son capaces de resolver un problema real en la industria de inspección de soldaduras en la industria

A continuación, un diagrama para ejemplificar de mejor forma al modelo




Diagramas 1- Proceso de creación y validación del modelo
Fuente: Elaboración propia

2.1.1 GOOGLE COLAB Y GOOGLE DRIVE

Se utilizó Google Colab y Google Drive para implementar y entrenar el modelo de inteligencia artificial. Google colab es una plataforma que permite codificar en Python, que permite usar recursos como GPU Y TPU del computador de manera gratuita.

Entendible Google drive se utilizó como plataforma de almacenamiento en la nube para albergar las imágenes de soldaduras que estaban clasificados en carpetas de acuerdo al defecto apreciado. La sincronización entre Google Colab y Google drive permitió tener un mejor manejo y acceso a los datos ya que al incorporar el framework desde el drive al entorno de colab se pudo cargar directamente las imágenes desde el software de almacenamiento hasta el motor de Google Colab por lo que el procesamiento de la imagen y la alimentación al modelo fue sencillo

En conjunto, el uso **de Google Colab y Google Drive** brinda una solución eficiente, para poder ajustar y ejecutar el modelo



```
[ ] from google.colab import drive
    drive.mount('/content/gdrive')
    !ls
```

*Ilustración 7- Código Google Drive
Fuente: Elaboración propia Google Colab*

Este fragmento de código muestra cómo se conecta Google Colab con Google Drive, para entrenar el modelo o dar resultado, es una buena forma de almacenar y desarrollar en la nube

Por ejemplo:

- Las imágenes del dataset que se entrenan en el modelo son almacenadas en Google Drive y accedidas mediante este código.
- Los resultados del modelo como métricas o gráficos pueden ser almacenados en el modelo.

(Google Research. (2023). Google Colaboratory. Google Colab. <https://colab.research.google.com>)

2.2 RELACIÓN CON NORMAS DE INSPECCIÓN VISUAL

El desarrollo del modelo de IA para la inspección visual de soldaduras está dentro de los estándares de las normas AWS.D1.1 y la ISO 13018, siendo así aplicable a la industria, la norma AWS D1.1 da los criterios de aceptabilidad de una soldadura, dando a conocer su estado optimo y sus discontinuidades

Por su parte, la norma ISO 13018 establece las condiciones ideales para hacer una inspección visual de calidad, dando sus parámetros de iluminación y ángulos de visión, todo esto se tomó en cuenta en el preprocesamiento de las imágenes para poder alcanzar la mayor calidad posible, además de hacer variaciones de esas imágenes dándole robustez al modelo

2.3 HERRAMIENTAS Y TECNOLOGÍAS UTILIZADAS EN EL DESARROLLO DEL MODELO

El desarrollo del modelo de inspección visual de soldaduras se basa en el uso de herramienta como, por ejemplo, Pytorch.

2.3.1 PYTORCH

Se utilizo Pytorch como herramienta principal para implementar y entrenar el modelo, debido a que es muy flexible ante distintas situaciones, además de ser eficiente para el manejo de redes neuronales convolucionales (CNN), Se utilizaron capas como nn.conv2d que sirvió para extraer el defecto de la soldadura para previamente clasificarlo, junto con nn.ReLU que introduce no linealidad y nn.MaxPool2d para reducir la dimensionalidad optimizando el modelo.

El procesamiento de imágenes se realizó mediante torchvision.transforms, redimensionado y convirtiendo a tensores y así lograr una consistencia de data set, luego datasets.ImageFolder organizo las imágenes

```
import torch
import torch.nn as nn
import torch.optim as optim
from torchvision import datasets, transforms
from torch.utils.data import DataLoader
```

Ilustración 8- Código Torch
Fuente: Elaboración Propia Google Colab

2.3.2 MACHINE LEARNING

El Machine Learning es un tópico de la inteligencia artificial que permite que un modelo aprenda patrones del entrenamiento dando lugar a realizar predicciones. En este proyecto, el machine learning es alimentado para la creación de un modelo el cual identifica y clasifica defectos de soldadura.

El proceso de entrenamiento incluye:

- Alimentar al modelo con el dataset y organizándolos en carpetas de entrenamiento validación y prueba.
- Ajustar los parámetros para mejorar la eficiencia y capacidad del modelo
- Evaluar el desempeño utilizando métricas y datos

(Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.)

2.3.3 VISIÓN COMPUTACIONAL

La vision computacional es el topico donde se le permite al modelo de inteligencia artificial analizar imágenes. En este proyecto se procesan las imágenes de soldaduras extrayendo sus características claves que les da el defecto.

- Preprocesamiento de imágenes, como redimensionamiento y normalización.
- Aumento de datos para mejorar la diversidad y la cantidad de ejemplos de entrenamiento.
- Identificación de patrones visuales como grietas, poros o irregularidades en las soldaduras.

El objetivo final de esto es entregar un modelo el cual sea capaz de analizar la data, extraer información importante y tomar la decisión de en qué categoría ingresar la imagen de la soldadura

(Szeliski, R. (2021). Computer Vision: Algorithms and Applications. Springer.)

2.3 SINERGIA ENTRE MACHINE LEARNING Y VISIÓN COMPUTACIONAL PARA EL MODELO

La combinación de Machine Learning y Visión Computacional es una gran fortaleza ya que cada una desempeña un rol, el cual se complementan potenciando el desempeño del modelo

Por un lado, la Visión Computacional entrega al modelo la capacidad del modelo del análisis de imágenes para así entrenar al modelo. Con preprocesamiento y técnicas de aumento de dataset se aumenta el aprendizaje. Por otro lado, el machine learning convierte toda la data en aprendizaje dando la capacidad de análisis y de predicción según los patrones aprendidos

La buena sinergia entre estas áreas se manifiesta en:

- **Automatización Completa:** La Visión Computacional prepara el dataset, mientras que el Machine Learning clasifica el dataset
- **Capacidad de Generalización:** El uso de técnicas de aumento de dataset, dio variedad de situaciones que se pueden afrontar en una industria
- **Flexibilidad y Escalabilidad:** La integración de ambas tecnologías permite al modelo ser más flexible a diferentes situaciones.

En resumen, la unión de Machine Learning y Visión Computacional no solo fortalece el proyecto, sino que también lo es una solución práctica para la inspección visual automatizada de soldadura.

2.5 ARQUITECTURA DEL MODELO DE INTELIGENCIA ARTIFICIAL

El modelo se diseñó en base a redes neuronales convolucionales (CNN), una arquitectura utilizada para el análisis y clasificación de imágenes, ya que al estar diseñadas para la identificación de patrones lo hace una arquitectura ideal para dicha función

(Alsarhan et al., 2024))

2.5.1 CAPAS CONVOLUCIONALES

El modelo este compuesto por varias capas convolucionales, cuya función es detectar las características de las imágenes, cada capa convolucional aplica filtros en las imágenes con lo cual va detectando los elementos más relevantes para su clasificación, al hacer esto en este caso el modelo será capaz de analizar y clasificar entre una soldadura en buen estado con una que posee algún defecto.

((Cruz et al., 2020))

2.5.2 CAPAS DE MAXPOOLING

Posterior a las capas convolucionales, se ingresaron capas de agrupamiento (MaxPooling). El propósito de esto es reducir la dimensión de las capas de características, disminuyendo así la cantidad de datos que el modelo debe procesar sin perder información ni confundir al modelo. Al aplicar esto mejora la eficiencia del modelo ya que lo ayuda a enfocarse en la información más destacada eliminando data que interfiera o confunda en la detección específica del modelo

Layer (type)	Output Shape	Param #
conv2d (conv2d)	(None, 496, 496, 32)	896
batch_normalization (batchnormalization)	(None, 496, 496, 32)	128
conv2d_1 (conv2d)	(None, 496, 496, 32)	9,248
max_pooling2d (MaxPooling2D)	(None, 248, 248, 32)	0
dropout (dropout)	(None, 248, 248, 32)	0
conv2d_2 (conv2d)	(None, 248, 248, 64)	18,496
batch_normalization_1 (batchnormalization)	(None, 248, 248, 64)	256
conv2d_3 (conv2d)	(None, 248, 248, 64)	36,928
conv2d_4 (conv2d)	(None, 248, 248, 64)	36,928
max_pooling2d_1 (MaxPooling2D)	(None, 124, 124, 64)	0
dropout_1 (dropout)	(None, 124, 124, 64)	0
flatten (Flatten)	(None, 93792)	0
dense (dense)	(None, 64)	59,969,600
dropout_2 (dropout)	(None, 64)	0
dense_1 (dense)	(None, 32)	2,080
output (dense)	(None, 5)	165
Total params: 69,074,725 (229.17 MB)		
Trainable params: 69,074,533 (229.17 MB)		
Non-trainable params: 192 (768.00 B)		

Ilustración 9- Código MaxPooling
Fuente: Elaboración Propia Google Colab

2.5.3 CAPAS DROPOUT

Para prevenir el sobreajuste, esto ocurre cuando el modelo aprende y no generaliza bien a nuevos datos. Para esto se incluyeron capas de regularización como **Dropout**. Estas capas apagan una proporción de las neuronas durante el entrenamiento, haciendo que el modelo aprenda características más generales en lugar de aprender de datos más específicos que pueden entorpecer el proceso, con Dropout se optimiza el modelo

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 498, 498, 32)	896
batch_normalization (BatchNormalization)	(None, 498, 498, 32)	128
conv2d_1 (Conv2D)	(None, 496, 496, 32)	9,248
max_pooling2d (MaxPooling2D)	(None, 248, 248, 32)	0
dropout (Dropout)	(None, 248, 248, 32)	0
conv2d_2 (Conv2D)	(None, 246, 246, 64)	18,496
batch_normalization_1 (BatchNormalization)	(None, 246, 246, 64)	256
conv2d_3 (Conv2D)	(None, 244, 244, 64)	36,928
conv2d_4 (Conv2D)	(None, 242, 242, 64)	36,928
max_pooling2d_1 (MaxPooling2D)	(None, 121, 121, 64)	0
dropout_1 (Dropout)	(None, 121, 121, 64)	0
flatten (Flatten)	(None, 937024)	0
dense (Dense)	(None, 64)	59,969,600
dropout_2 (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 32)	2,080
output (Dense)	(None, 5)	165
Total params: 60,074,725 (229.17 MB)		
Trainable params: 60,074,533 (229.17 MB)		
Non-trainable params: 192 (768.00 B)		

Ilustración 10- Código DropOut
Fuente: Elaboración propia Google Colab

2.5.4 FUNCIÓN RELU Y SOFTMAX

se utilizó la función ReLu (Rectified Linear Unit) en capas ocultas, ya que es efectiva en el mejor de problemas de gradientes que pueden ocurrir durante el entrenamiento del dataset. Para la capa de salida, se aplicó Softmax, que permita la clasificación de las imágenes según el defecto que contenga la soldadura

```
nb_train_samples = 613
nb_validation_samples = 80

model = Sequential()

inputShape = (height_shape, width_shape, 3)
model.add(Conv2D(32, (3, 3), activation='relu', input_shape=inputShape)) # Agrega activación
model.add(BatchNormalization())
model.add(Conv2D(32, (3, 3), activation='relu')) # Agrega activación
model.add(MaxPool2D())
model.add(Dropout(0.25)) # Añade dropout

model.add(Conv2D(64, (3, 3), activation='relu')) # Agrega activación
model.add(BatchNormalization())
model.add(Conv2D(64, (3, 3), activation='relu')) # Agrega activación
model.add(Conv2D(64, (3, 3), activation='relu')) # Agrega activación
model.add(MaxPool2D())
model.add(Dropout(0.25)) # Añade dropout

model.add(Flatten())
model.add(Dense(64, activation='relu'))
model.add(Dropout(0.5)) # Añade dropout
model.add(Dense(32, activation='relu'))
model.add(Dense(num_classes, activation='softmax', name='output'))

model.summary()
```

*Ilustración 11- Código Relu y SoftMax
Fuente:Elaboración propia Google Colab*

2.5.5 CONFIGURACIÓN DE HIPERPARÁMETROS

Los hiperparametros son valores los cuales pueden ser configurados para dejar al modelo lo mejor optimizado:

Tamaño del lote (batch size): El tamaño del batch size determina la cantidad de imágenes que son procesadas. Inicialmente se determinó 16, pero debido a un incremento del dataset se reajusto a 32 para que sea capaz de procesar mayor cantidad de imágenes

Número de épocas (epochs): El modelo fue entrenado durante 100 épocas, lo cual significa que las imágenes fueron procesadas un total de 100 veces

Función de pérdida (**loss function**): La función de pérdida fue Categorical Crossentropy, que mide pérdida entre predicciones del modelo y la función real, esto ayudo a ver cuál es la clasificación que está dando problemas, ya que calcula la probabilidad de acierto en cada clase, y además penaliza al modelo si su predicción es incorrecta

```
width_shape = 500
height_shape = 500
num_classes = 5
epochs = 100
batch_size = 32
```

*Ilustración 12- Configuración de Hiperparametros
Fuente: Elaboración propia Google Colab*

2.5.6 IMPACTO DE LOS HIPERPARAMETROS AL MODELO

La configuración adecuada de los hiperparemetros fue útil para que el modelo alcanzara un rendimiento adecuado y fuera capaz de reconocer toda información nueva clasificándolo donde corresponde. Los ajustes realizados inicialmente ayudaron a optimizar el entrenamiento y garantizo que el modelo pueda usar los recursos computacionales sin comprometer su desempeño

(Omdena, 2023)

```
Epoch 1/100
19/19 ————— 71s 3s/step - accuracy: 0.2352 - loss: 1.7813 - val_accuracy: 0.2188 - val_loss: 1.6999
Epoch 2/100
19/19 ————— 2s 91ms/step - accuracy: 0.3750 - loss: 1.6141 - val_accuracy: 0.3125 - val_loss: 1.5428
Epoch 3/100
19/19 ————— 58s 2s/step - accuracy: 0.2783 - loss: 1.6159 - val_accuracy: 0.2656 - val_loss: 1.6123
Epoch 4/100
19/19 ————— 1s 26ms/step - accuracy: 0.3125 - loss: 1.5688 - val_accuracy: 0.2500 - val_loss: 1.6017
Epoch 5/100
19/19 ————— 81s 2s/step - accuracy: 0.2640 - loss: 1.6304 - val_accuracy: 0.1406 - val_loss: 1.6221
Epoch 6/100
19/19 ————— 1s 43ms/step - accuracy: 0.6667 - loss: 1.3654 - val_accuracy: 0.2500 - val_loss: 1.6594
Epoch 7/100
19/19 ————— 81s 2s/step - accuracy: 0.2493 - loss: 1.6052 - val_accuracy: 0.2188 - val_loss: 1.6173
Epoch 8/100
19/19 ————— 2s 57ms/step - accuracy: 0.3438 - loss: 1.4964 - val_accuracy: 0.2500 - val_loss: 1.6399
Epoch 9/100
19/19 ————— 47s 2s/step - accuracy: 0.2332 - loss: 1.5814 - val_accuracy: 0.2656 - val_loss: 1.6165
Epoch 10/100
19/19 ————— 1s 24ms/step - accuracy: 0.2188 - loss: 1.6720 - val_accuracy: 0.2500 - val_loss: 1.5695
Epoch 11/100
19/19 ————— 80s 2s/step - accuracy: 0.2394 - loss: 1.5785 - val_accuracy: 0.2188 - val_loss: 1.6186
Epoch 12/100
19/19 ————— 1s 44ms/step - accuracy: 0.6667 - loss: 1.3622 - val_accuracy: 0.2500 - val_loss: 1.6360
Epoch 13/100
4/19 ————— 21s 1s/step - accuracy: 0.2891 - loss: 1.5691
```

*Ilustración 13- Épocas de entrenamiento
Fuente: Elaboración propia Google Colab*

2.6 PROCESAMIENTO DE IMÁGENES Y AUMENTO DE DATOS

El procesamiento de imágenes y el aumento de datos son pasos fundamentales en el desarrollo de modelos de inteligencia artificial. Estas etapas permiten preparar los datos para que el modelo pueda aprender los patrones relevantes de las imágenes, mejorando así no nivel de interpretación y rendimiento por encima de sus nuevos datos

2.6.1 PREPROCESAMIENTO

El preprocesamiento es el; paso número uno en el manejo de imágenes para entrenar un modelo. Esto comienza de la carga de imágenes desde Google Drive, donde se utilizaba como Nube la cual almacena de manera organizada en carpetas correspondientes según las carpetas de clasificación de soldaduras que vendrían siendo soldadura en buen estado y sus defectos establecidos previamente. Cada categoría contiene imágenes clasificadas en conjuntos de entrenamiento, validación y test

Una vez que las imágenes sean cargadas, pasan por un proceso de redimensionamiento que asegura que todas las imágenes tengan dimensiones estandarizadas (500x500 píxeles). Este paso es útil ya que dejara que el modelo requiere un tamaño uniforme para un proceso más eficiente.

Para facilitar y automatizar el proceso, se utilizó la herramienta ImageDataGenerator de Pytorch. Esta utilidad sirve para el preprocesamiento de forma más eficiente, sino que también ofrece funciones adicionales, como la generación de imágenes de forma automática durante el entrenamiento. Esto elimina la necesidad de cargar todo el conjunto de datos en memoria, además de esto sirve para estandarizar los datos, haciendo así que las imágenes se procesen de forma más uniforme y eficiente

2.6.2 PREPARACIÓN DE DATASET Y ESTRUCTURA DE CARPETA

El modelo de inteligencia artificial desde de la calidad y organización de dataset de su entrenamiento, en este proyecto las imágenes de entrenamiento fueron clasificadas en cinco carpetas, correspondiendo a la soldadura en buen estado y los 4 defectos seleccionados.

1. **Soldadura en buen estado** (Tipo 1)
2. **Agrietamiento** (Tipo 2)
3. **Porosidad** (Tipo 3)
4. **Salpicadura** (Tipo 4)
5. **Socavación** (Tipo 5)

Cada carpeta contiene app. 100 imágenes, que fueron distribuidas en las siguientes carpetas:

Nombre	Fecha de modificación	Tipo	Tamaño
Agrietamiento tipo 2	03-10-2024 16:58	Carpeta de archivos	
Falta de Fusión	12-09-2024 19:45	Carpeta de archivos	
Porosidad tipo 3	01-10-2024 19:19	Carpeta de archivos	
Salpicadura tipo 4	03-10-2024 15:57	Carpeta de archivos	
socavación tipo 5	12-09-2024 19:45	Carpeta de archivos	
Soldadura en Buen estado tipo 1	12-09-2024 19:45	Carpeta de archivos	

Ilustración 14- Carpetas de Defectos
Fuente:Elaboración propia

- **Carpeta de entrenamiento (Train):** 20 Imagenes
- **Carpeta de prueba (Test):** 72 imágenes
- **Carpeta de validación (Val):** 8 imágenes

Este proceso permitió que la inteligencia artificial fuera entrenada por imágenes tanto soldaduras en buen estado como con discontinuidades específicas. Además, todas las imágenes fueron convertidas a un tamaño de 500x500 pixeles y en formato jpg, jpeg y png




Ilustración 15- Configuración de imágenes
Fuente: Elaboración propia




Ilustración 16- Configuración de Carpetas
Fuente: Elaboración propia

Categoría	Entrenamiento	Val	Test	Total
Buen Estado	20	8	72	100
Agrietamiento	20	8	72	100
Porosidad	20	8	72	100
Salpicadura	20	8	72	100
Socavación	20	8	72	100

Tabla 3-Distribución de imágenes en carpetas
Fuente: Elaboración propia

2.6.3 AUMENTO DE DATOS: ZOOM, ROTACIÓN Y DESPLAZAMIENTO DE IMÁGENES

El modelo de inteligencia artificial diseñado para la inspección de soldadura cuenta con funciones de aumento de dataset. Estas funciones incluyen la rotación de imágenes hasta 20 grados, también se aplicó zoom de hasta un 20% durante el entrenamiento. Adicionalmente se le agregó un desplazamiento horizontal y vertical de hasta un 10% en cada imagen.

Al implementar esto se enriqueció el conjunto de dataset y mejorar la capacidad de detección del modelo. Al exponerlo a variaciones el modelo es capaz de aprender e identificar discontinuidades desde diferentes perspectivas lo cual lo hace más aplicable a un caso real en una industria.

Estas técnicas de aumento de dataset contribuyeron a la robustez del modelo de inteligencia artificial, ya que amplía la diversidad de ejemplos el cual el modelo procesa durante el entrenamiento sin la necesidad de recolectar imágenes nuevas.

```
train_datagen = ImageDataGenerator(
    rotation_range=20,
    zoom_range=0.2,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=True,
    vertical_flip=False,
    preprocessing_function=preprocess_input)

valid_datagen = ImageDataGenerator(
    rotation_range=20,
    zoom_range=0.2,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=True,
    vertical_flip=False,
    preprocessing_function=preprocess_input)

train_generator = train_datagen.flow_from_directory(
    train_data_dir,
    target_size=(width_shape, height_shape),
    batch_size=batch_size,
    #save_to_dir='',
    class_mode='categorical')

validation_generator = valid_datagen.flow_from_directory(
    validation_data_dir,
    target_size=(width_shape, height_shape),
    batch_size=batch_size,
    #save_to_dir='',
    class_mode='categorical')
```

*Ilustración 17- Código Aumento de Dataset
Fuente: Elaboración propia Google Colab*

2.6.4 IMÁGENES EN ESCALA DE GRISES

En búsqueda de mejorar la correlación del modelo de inteligencia artificial, se decidió realizar una modificación del dataset, cada una de las imágenes utilizadas en el entrenamiento validación y prueba fueron convertidas en escala de grises. Este cambio se realizó para simplificar la complejidad de análisis del color y enfocarse a las características estructurales de forma neta como así también las texturas de las soldaduras, las cuales pueden ser útiles para la detección de defectos en soldaduras.




Ilustración 18- Imagen original
Fuente: Elaboración propia




Ilustración 19- Imagen original en escala de grises
Fuente: Elaboración propia




Ilustración 20- Imágenes Convertidas en escala de grises
Fuente: Elaboración propia

2.6.4.1 RESULTADO DE LA MODIFICACIÓN DE ESCALA DE GRISES A LAS IMAGENES

A pesar de que se esperaba que la conversión de las imágenes a **escala de grises** mejorara la correlación del modelo de inteligencia artificial, los resultados obtenidos no fueron los esperados. Después de realizar las pruebas con el conjunto de imágenes modificadas, se observó que la correlación en la validación del modelo **disminuyó del 40% al 30% aproximadamente**.

Este resultado dice que la información de colores originales era más relevante de lo que esperaba en la identificación de los defectos de la soldadura, al eliminar el color, el modelo perdió una parte importante el cual parece ser útil para la detección eficiente

Aunque el enfoque de escala de grises simplificaba al análisis visual, esto no favoreció al rendimiento del modelo a detectar discontinuidades en uniones soldadas, lo que nos llevó a concluir que el usar imágenes a color es más efectivo que con escala de grises.

```
Epoch 60/100
19/19 — 2s 119ms/step - accuracy: 0.1875 - loss: 1.5784 - val_accuracy: 0.3750 - val_loss: 1.5184
Epoch 61/100
19/19 — 24s 985ms/step - accuracy: 0.2830 - loss: 1.5393 - val_accuracy: 0.2500 - val_loss: 1.6056
Epoch 62/100
19/19 — 3s 146ms/step - accuracy: 0.2500 - loss: 1.6319 - val_accuracy: 0.2500 - val_loss: 1.5789
Epoch 63/100
19/19 — 26s 955ms/step - accuracy: 0.3466 - loss: 1.5086 - val_accuracy: 0.2500 - val_loss: 1.5902
Epoch 64/100
19/19 — 3s 146ms/step - accuracy: 0.3750 - loss: 1.5158 - val_accuracy: 0.1250 - val_loss: 1.7077
Epoch 65/100
19/19 — 37s 982ms/step - accuracy: 0.2716 - loss: 1.5608 - val_accuracy: 0.1875 - val_loss: 1.6766
Epoch 66/100
19/19 — 3s 139ms/step - accuracy: 0.5000 - loss: 1.2370 - val_accuracy: 0.2500 - val_loss: 1.4936
Epoch 67/100
19/19 — 37s 997ms/step - accuracy: 0.2835 - loss: 1.5596 - val_accuracy: 0.2188 - val_loss: 1.6146
Epoch 68/100
19/19 — 3s 128ms/step - accuracy: 0.3750 - loss: 1.5099 - val_accuracy: 0.5000 - val_loss: 1.5866
Epoch 69/100
19/19 — 38s 966ms/step - accuracy: 0.2681 - loss: 1.5964 - val_accuracy: 0.2500 - val_loss: 1.6357
Epoch 70/100
19/19 — 2s 108ms/step - accuracy: 0.2500 - loss: 1.5899 - val_accuracy: 0.3750 - val_loss: 1.5719
```

Ilustración 21- Épocas
Fuente: Elaboración propia Google Colab




Ilustración 22- Grafica entrenamiento escala de grises
Fuente: Elaboración propia Google Colab

En este caso la IA detecto bien, Tipo 1 (Soldadura en buen estado)




Ilustración 23- Detección Correcta de estado de soldadura
Fuente: Elaboración propia Google Colab




Ilustración 24-Matriz de confusión inicial
Fuente: Elaboración propia Google Colab

Sin embargo, podemos ver que el tipo 2 es decir agrietamiento. El modelo está muy confundido con el resto de las discontinuidades, lo cual es lo que se está intentando solucionar.

2.6.5 EFECTO ESPEJO

Para mejorar la capacidad del modelo se duplicaron el conjunto de datos aplicando a cada imagen un efecto espejo. Esto impacto al incremento la cantidad de dataset, creando a si el doble de variaciones a partir de las imágenes ya existentes en el modelo

Al aplicar el efecto espejo, se buscó proporcionar al modelo una representación de los patrones más amplia, con la finalidad de lograr un mejor entendimiento del modelo a las características claves de las imágenes de soldaduras con defectos, de esta forma se espera que el modelo aprenda de mejor manera las diferencias entre soldaduras en buen estado y aquellas con defectos




Ilustración 25-Grafica Efecto espejo
Fuente: Elaboración propia Google Colab


Epoch 30/100	19/19	0s 21ms/step	- accuracy: 1.0000 - loss: 1.0241 - val_accuracy: 0.0000e+00 - val_loss: 1.6689
Epoch 31/100	19/19	24s 923ms/step	- accuracy: 0.2330 - loss: 1.6271 - val_accuracy: 0.2188 - val_loss: 1.6409
Epoch 32/100	19/19	25s 99ms/step	- accuracy: 0.1875 - loss: 1.6109 - val_accuracy: 0.0000e+00 - val_loss: 1.6485
Epoch 33/100	19/19	39s 915ms/step	- accuracy: 0.2797 - loss: 1.6181 - val_accuracy: 0.2500 - val_loss: 1.5997
Epoch 34/100	19/19	0s 22ms/step	- accuracy: 0.0000e+00 - loss: 1.8351 - val_accuracy: 0.1250 - val_loss: 1.6802
Epoch 35/100	19/19	48s 875ms/step	- accuracy: 0.2131 - loss: 1.6301 - val_accuracy: 0.3750 - val_loss: 1.6023
Epoch 36/100	19/19	25s 114ms/step	- accuracy: 0.4375 - loss: 1.5165 - val_accuracy: 0.3750 - val_loss: 1.6121
Epoch 37/100	19/19	38s 835ms/step	- accuracy: 0.2476 - loss: 1.5866 - val_accuracy: 0.2188 - val_loss: 1.6023
Epoch 38/100	19/19	15s 13ms/step	- accuracy: 0.0625 - loss: 1.6197 - val_accuracy: 0.1250 - val_loss: 1.6257
Epoch 39/100	19/19	26s 1s/step	- accuracy: 0.2246 - loss: 1.6065 - val_accuracy: 0.2500 - val_loss: 1.6050
Epoch 40/100	19/19	15s 32ms/step	- accuracy: 0.1875 - loss: 1.6225 - val_accuracy: 0.1250 - val_loss: 1.6641
Epoch 41/100	19/19	37s 944ms/step	- accuracy: 0.2694 - loss: 1.5822 - val_accuracy: 0.1562 - val_loss: 1.6061
Epoch 42/100	19/19	15s 28ms/step	- accuracy: 0.2500 - loss: 1.5774 - val_accuracy: 0.2500 - val_loss: 1.5895
Epoch 43/100	19/19	41s 995ms/step	- accuracy: 0.2021 - loss: 1.5829 - val_accuracy: 0.1250 - val_loss: 1.6239
Epoch 44/100	19/19	15s 17ms/step	- accuracy: 0.1875 - loss: 1.5883 - val_accuracy: 0.3750 - val_loss: 1.5937
Epoch 45/100	19/19	23s 890ms/step	- accuracy: 0.3134 - loss: 1.5688 - val_accuracy: 0.1562 - val_loss: 1.6251
Epoch 46/100	19/19	15s 13ms/step	- accuracy: 0.2500 - loss: 1.5504 - val_accuracy: 0.2500 - val_loss: 1.5553
Epoch 47/100	19/19	41s 939ms/step	- accuracy: 0.2872 - loss: 1.5171 - val_accuracy: 0.1562 - val_loss: 1.6132
Epoch 48/100	19/19	15s 35ms/step	- accuracy: 1.0000 - loss: 1.5651 - val_accuracy: 0.3750 - val_loss: 1.5176

Ilustración 26- Entrenamiento Efecto espejo
Fuente: Elaboración propia Google Colab

Podemos apreciar que se logró una leve mejora, llegando por primera vez una precisión de entrenamiento de un 100% en un par de oportunidades.

2.6.5.1 AJUSTE DE BATCH SIZE

Al aplicar el efecto Espejo la cantidad de imágenes se duplicó, por lo que fue necesario ajustar ciertos hiperparámetros del código para que el modelo sea capaz de manejar el nuevo volumen de datos, el modelo anteriormente estaba configurado con un Batch Size de 16 lo cual fue un error por la mayor carga de procesamiento que se le aplicaba al modelo, para resolver esto hubo un ajuste a 32 de Batch Size, permitiendo así al modelo a procesar la nueva densidad de imágenes.

A screenshot of a code editor with a dark background. On the left, there is a play button icon. The code is written in a light-colored font and consists of five lines of assignments: `width_shape = 500`, `height_shape = 500`, `num_classes = 5`, `epochs = 100`, and `batch_size = 32`.

```
width_shape = 500
height_shape = 500
num_classes = 5
epochs = 100
batch_size = 32
```

*Ilustración 27- Ajuste Hiperparámetros
Fuente: Elaboración propia Google Colab*

2.6.6 RESUMEN: RELACIÓN DEL PROCESAMIENTO Y PREPARACIÓN DEL DATASET CON EL MODELO

El procesamiento y preparación del dataset permitió que el modelo pueda identificar los patrones visuales de las soldaduras que poseían discontinuidades, desde el comienzo el enfoque se centró en crear un conjunto de datos estructurado, para que así el modelo tenga una buena base para aprender.

Las imágenes fueron clasificadas en las cinco categorías de defectos de soldadura, las cuales fueron distribuidas en carpetas de entrenamiento validación y prueba. Esta organización permitió que el modelo pueda aprender de una forma estructurada y ordenada cada uno de los defectos que puede poseer un cordón de soldadura

Además, para facilitar más el entendimiento del modelo las imágenes fueron estandarizadas en 500x500 píxeles y todas las imágenes en formato JPG, JPEG Y PNG permitiendo así un entrenamiento más consistente

Las técnicas de aumento de datos, como la rotación, zoom, desplazamiento y reflejo aportaron bastante en una preparación del dataset robusta, además de esto le dio más flexibilidad al modelo para detectar anomalías de forma más variada y cercana a una aplicación real en una industria

En cuanto al entrenamiento, gracias a Google Drive y Google Colab se pudo hacer un procesamiento de muchas imágenes, con herramientas como ImageDataGenerator permitió elaborar más data de entrenamiento para el modelo, además de optimizar los recursos computacionales, se tuvieron que hacer ajustes de parámetros como el ajuste de batch size lo cual permitió al modelo procesar bien un volumen mayor de imágenes

2.7 EVALUACIÓN DEL DESEMPEÑO

La evaluación del desempeño es una etapa para ver que tan bien está cumpliendo el modelo con su identificación de estado de una soldadura y clasificarla en su categoría correspondiente, esto a través de métricas y análisis. Esto da a lugar a identificar fortalezas y debilidades y oportunidades de mejora para el modelo

2.7.1 MÉTRICAS DE EVALUACIÓN

Para la medición de desempeño del modelo, se utilizaron métricas de medición de problemas de clasificación, esto ofreció una visión sobre la precisión del modelo en sus predicciones.

Precisión (Accuracy): La precisión es una métrica que mide el porcentaje de predicciones efectivas relación con el total realizadas, si bien es útil para reflejar rendimiento, esto también afecta a un desbalanceo de categorías ya que una categoría puede confundir otra categoría influyendo a la precisión del modelo

Recall: Conocido como “Sensibilidad”, mide la capacidad para identificar correctamente los casos de una categoría en particular

F1-Score: Esta métrica es una combinación de precisión y recall en un único valor, calculando un promedio entre ellas, es útil en el caso que haya un equilibrio entre el mínimo de falsos positivos con falsos negativos dando una visión balanceada de rendimiento del modelo

Matriz de Confusión: la matriz de confusión es una herramienta visual la cual te permite hacer un análisis de las predicciones del modelo en cada categoría y como se relacionan entre ellas, esto ayuda a identificar las categorías que tengan menor rendimiento y con cual categoría se confunde o tiene dificultad para distinguir entre categorías




Ilustración 28- Matriz de confusión
Fuente: Elaboración propia Google Colab

El análisis de todas estas métricas permitió detectar el desempeño del modelo de forma más específica en la clasificación de defectos en imágenes de soldaduras, el modelo cuenta con un mejor desempeño en las soldaduras en buen estado, pero muestra dificultadores en la detección de ciertas categorías, esto puede deberse a ciertas similitudes visuales entre defectos el cual el modelo se confunde

2.1 LIMITACIÓN DEL MODELO

Aunque el modelo sea útil para identificar defectos externos en cordones de soldadura, presenta una gran limitación al depender exclusivamente de imágenes, al ser basado en inspección visual el modelo no es capaz de detectar anomalías internas que pueda presentar la soldadura, como puede ser porosidades o grietas

Esto se debe a que la visión computacional analiza solo características superficiales que son captadas en la imagen, para poder llegar a analizar defectos internos sería necesario implementar tecnologías más avanzadas como ultrasonido o rayos X

A pesar de esto, el enfoque basado en inteligencia artificial sigue siendo una herramienta que mejora la eficiencia en la detección de discontinuidades superficiales, de manera rápida y automatizada, además este modelo da a lugar a una mejora continua dado a la implementación de nuevas tecnologías que anularían esta limitación




Ilustración 29- Soldadura con Poros internos
Fuente: Shutterstock

En este caso esta soldadura cuenta con defectos al interior de la soldadura lo cual el Modelo de IA no sería capaz de reconocer esta discontinuidad.

2.9 OPTIMIZACIÓN Y MEJORA DEL MODELO

Para mejorar el desempeño del modelo de IA y alcanzar la precisión del 87%, se realizaron acciones enfocadas en la optimización de los datos del modelo. Esto fue clave para superar limitaciones que fueron captadas inicialmente en el modelo.

Se procedió a optimizar el código, ajustando parámetros y configuración que influyen en la capacidad que tiene el modelo para aprender.

Otro paso fue la depuración del dataset, donde se identificaron las imágenes que generaban confusión y fueron eliminadas del modelo para que no siga aprendiendo de ellas, estas imágenes presentaban defectos visualmente similares a otros o contaba con otros defectos leves confundiendo así al modelo, al eliminar esto el modelo se volvió más consistente.

```
Imagen Copia de Soldadura en buen estado 53.png pertenece a: Tipo tensor([1])
Imagen Copia de Soldadura en buen estado 54.jpg pertenece a: Tipo tensor([1])
Imagen Copia de Soldadura en buen estado 55.png pertenece a: Tipo tensor([2])
Imagen Copia de Soldadura en buen estado 56.jpg pertenece a: Tipo tensor([1])
Imagen Copia de Soldadura en buen estado nuevo 8.jpg pertenece a: Tipo tensor([1])
Imagen Soldadura en buen estado 47.jpg pertenece a: Tipo tensor([1])
Imagen Soldadura en buen estado 48.jpg pertenece a: Tipo tensor([1])
Imagen soldadura en buen estado.4124214.jpg pertenece a: Tipo tensor([1])
Porcentaje de tipos en la carpeta Carpeta 1:
```

*Ilustración 30- Detección de soldaduras en buen estado
Fuente: Elaboración propia Google Colab*

Finalmente, se entrenó al modelo con un nuevo dataset más adecuado y claro de cada categoría de discontinuidades de soldaduras. Gracias a esta selección el modelo identificó de forma más efectiva el estado de una soldadura. Con este reentrenamiento el modelo aumentó su capacidad de generalización e identificación gracias a su mayor robustez y consistencia.

2.10 RESULTADOS DE LAS PRUEBAS PRELIMINARES

Los resultados obtenidos del modelo, están representados en la matriz de confusión y los porcentajes de precisión por categoría, mostrando un desempeño de forma general el cual permite evaluar su desempeño en la detección y clasificación de discontinuidades en soldadura

2.10.1 DESEMPEÑO GLOBAL DEL MODELO

La matriz de confusión entrega una visión general del rendimiento por cada tipo de discontinuidades

- El modelo logra detectar correctamente las categorías cuando una clase domina el conjunto de datos.
- Los porcentajes de predicción más altos corresponden a:
 - **Carpeta 1 (Tipo1):** 90.00%
 - **Carpeta 2 (Tipo2):** 94.12%
 - **Carpeta 3 (Tipo3):** 90.48%
 - **Carpeta 4 (Tipo4):** 83.33%
 - **Carpeta 5 (Tipo5):** 75.00%

Esto nos dice que el modelo tiene una gran capacidad en la detección en la detección de clases de discontinuidades, aunque tiene presente confusiones cuando las discontinuidades son leves.




Ilustración 31- Matriz de confusión final
Fuente: Elaboración propia Google Colab

2.11 ANÁLISIS POR CATEGORÍAS:

Carpeta 1 (Soldadura en buen estado - Tipo1):

- Precisión del **90.00%**, pero existe una leve confusión con el agrietamiento (Tipo 2)
- Esto puede ser ocasionado con defectos leves con algunas grietas que el modelo detecta como si estuvieran en buen estado

Porcentaje de tipos en la carpeta Carpeta 1:

```
Tipo1: 90.00%
Tipo2: 10.00%
Tipo3: 0.00%
Tipo4: 0.00%
Tipo5: 0.00%
```

*Ilustración 32- Precisión soldadura en buen estado
Fuente: Elaboración propia Google Colab*

Carpeta 2 (Agrietamiento - Tipo2):

- Logra un **94.12%** de precisión.
- Leve confusión con la salpicadura (5.88%) se puede deber a similitudes superficiales entre discontinuidades

Porcentaje de tipos en la carpeta Carpeta 2:

```
Tipo1: 0.00%
Tipo2: 94.12%
Tipo3: 0.00%
Tipo4: 5.88%
Tipo5: 0.00%
```

*Ilustración 33- Precisión Agrietamiento
Fuente: Elaboración propia Google Colab*

Carpeta 3 (Porosidad - Tipo3):

- Cuenta con precisión del **90.48%**.
- Hay errores leves al identificar por confusiones con soldaduras en buen estado (9.52%), lo cual indica que una porosidad ligera puede ser detectada como soldadura en buen estado.

Porcentaje de tipos en la carpeta Carpeta 3:

Tipo1: 9.52%
Tipo2: 0.00%
Tipo3: 90.48%
Tipo4: 0.00%
Tipo5: 0.00%

Ilustración 34- Precisión Porosidad
Fuente: Elaboración propia Google Colab

Carpeta 4 (Salpicadura - Tipo4):

- La precisión es de **83.33%**
- Las imágenes con poca salpicadura se clasifican erróneamente con soldaduras en buen estado (**11.11%**) y porosidad (**5.56%**)

Porcentaje de tipos en la carpeta Carpeta 4:

Tipo1: 11.11%
Tipo2: 0.00%
Tipo3: 5.56%
Tipo4: 83.33%
Tipo5: 0.00%

Ilustración 35- Precisión Salpicadura
Fuente: Elaboración propia Google Colab

Carpeta 5 (Socavación - Tipo5):

- Se alcanza un **80.00%** de precisión, siendo esta la categoría con menor rendimiento.
- Existe confusión entre **Tipo1** de un 12.50%, **Tipo2 y Tipo3**(6.25% cada uno), lo cual nos quiere decir que la socavación tiene cierta confusión con el resto de los defectos

Porcentaje de tipos en la carpeta Carpeta 5:

```
Tipo1: 12.50%
Tipo2: 6.25%
Tipo3: 6.25%
Tipo4: 0.00%
Tipo5: 75.00%
```

*Ilustración 36-Presición Socavación
Fuente: Elaboración propia Google Colab*

2.11.1 CASO DE SOLDADURA EN BUEN ESTADO

Podemos ver que el modelo de IA detecto de forma correcta que se trata de una soldadura en buen estado (Tipo 1)



*Ilustración 37- Caso Soldadura en buen estado
Fuente: Elaboración propia Google Colab*

2.11.2 CASO DE AGRIETAMIENTO

Podemos ver que el modelo de IA detecto de forma correcta que se trata de una soldadura con agrietamiento (Tipo 2)



Ilustración 38- Caso Agrietamiento
Fuente: Elaboración propia Google Colab

2.11.3 CASO DE POROSIDAD

Podemos ver que el modelo de IA detecto correctamente que esta soldadura presenta porosidad (Tipo 3)



Ilustración 39- Caso Porosidad
Fuente: Elaboración propia Google Colab

2.11.4 CASO DE SALPICADURA

Podemos ver que el modelo de IA detecto de forma correcta que la soldadura presenta Salpicadura (Tipo 4)



*Ilustración 40- Caso Salpicadura
Fuente: Elaboración propia Google Colab*

2.11.5 CASO DE SOCAVACIÓN

Podemos ver que el modelo de IA detecto de forma correcta que esta soldadura presenta socavación (Tipo 5)




*Ilustración 41- Caso Socavación
Fuente: Elaboración propia Google Colab*

2.12 ANÁLISIS DE ERRORES EN DETECCIÓN DE ANOMALIAS

El desempeño del modelo para clasificar discontinuidades en soldaduras ha mostrado ciertos errores, principalmente en discontinuidades que son similares entre sí o cuando hay defectos muy leves, a partir del análisis de la matriz de confusión, se hizo una descripción de los problemas detectados:

1. Soldadura en buen estado (Tipo 1):

- Esta categoría presenta un 90.00% de precisión, pero tiene ciertas confusiones con agrietamiento (tipo 2) en un 10% de los casos
- **Motivo del error:** defectos leves a la vista, grietas superficiales o poros leves, que no son lo suficientemente visibles para el modelo
- **Ejemplo:** Soldaduras con pequeñas grietas o salpicaduras escasas se confunden con soldaduras en buen estado.

2. Agrietamiento (Tipo 2):

- El modelo alcanza un 94.12% de precisión en esta categoría, presenta una leve confusión con salpicadura (tipo 4)
- **Motivo del error:** Grietas leves se le hace similar a pequeñas acumulaciones salpicadura.
- **Observación:** Aunque el modelo clasifica bien las grietas pronunciadas, las sutiles siguen siendo un reto.

3. Porosidad (Tipo 3):

- La precisión en la clasificación de porosidad es del 90.48%, pero presenta confusión con la soldadura en buen estado (tipo 1) en un 9.52%
- **Motivo del error:** Porosidad leve puede ser confundido debido a su apariencia parcialmente limpia
- **Ejemplo:** Las pequeñas cavidades en la superficie pueden confundir con una soldadura normal

4. Salpicadura (Tipo 4):

- El modelo tiene un 83.00% de precisión, sin embargo, contiene errores con soldaduras en buen estado (tipo 1) 11.11% y tipo 3 (5.56%)
- **Motivo del error:**
 - Salpicaduras **escasas** se clasifican erróneamente como soldaduras en buen estado
 - Salpicaduras con patrones irregulares o aislados pueden confundirse con porosidad
- **Observación:** cuando la salpicadura es abundante el modelo lo detecta sin problemas.

5. Socavación (Tipo 5):

- Esta categoría presenta el peor desempeño con un 75.00% de precisión, se confunde con todos los tipos de defectos
- **Motivo del error:** la irregularidad en los bordes debido a la socavación es difícil de diferenciar, debido a su similar apariencia de una soldadura en buen estado
-
- **Observación:** La baja cantidad de datos específicos y la similitud visual con otras clases afectan el rendimiento del modelo.

2.4 ANÁLISIS DE LA GENERACIÓN DEL MODELO DE IA

En el desarrollo del modelo de inteligencia artificial se establecieron conjuntos de datos organizados en cinco categorías que corresponden a la soldadura en buen estado y en sus 4 defectos entrenados en el modelo alineados con las normativas seleccionadas del capítulo 1. Se llevo a cabo un preprocesamiento de imágenes, incluyendo redimensionamiento, ajuste de formato y técnicas de aumento de dataset con el objetivo de mejorar la capacidad del modelo ante variaciones en las inspecciones que se pueden dar en una industria.

En términos de arquitectura del modelo de inteligencia artificial, el modelo de CNN diseño capas convolucionales y de agrupación, las cuales sirvieron para extraer características relevantes de las imágenes de soldaduras, además se implementaron funciones ReLU y capas de salida Softmax para así asignar valores de probabilidad de detección correcta de cada clase. Durante el entrenamiento se realizaron ajustes de hiperparametros como el Batch Size y numero de épocas de entrenamiento del modelo

El modelo fue entrenado con una base de datos de Google drive en colaboración de Google colab que sirvió para el codificado de la inteligencia artificial, gestionando el procesamiento de un gran volumen de imágenes. Se utilizaron métricas como recall, precisión y F1-score permitiendo medir el rendimiento del sistema para detectar anomalías en soldaduras según su clase

En Conclusión, la implementación del modelo de IA ha sido evidenciado que sea funcional para inspección visual de soldaduras, se logró desarrollar un sistema capaz de analizar imágenes de soldaduras y clasificar discontinuidades con un porcentaje de acierto de un 87%, demostrando así su capacidad para identificar y clasificar de forma correcta el estado de una soldadura, con todo esto se permitió alcanzar el propósito del objetivo específico número dos, dando las bases para futuras optimizaciones del modelo

CAPITULO 3: EVALUACIÓN Y VALIDACIÓN DEL MODELO DE
INSPECCIÓN VISUAL DE SOLDADURAS

3.1 INTRODUCCIÓN A LA EVALUACIÓN DEL MODELO

Este capítulo se centrará en la prueba de campo del modelo, para evaluar su desempeño en situaciones más similares a las que se le puede dar en una industria, pudiendo ver si logra cumplir con identificaciones más claras y objetivas respecto la inspección de soldaduras

Asimismo, este capítulo detalla como las pruebas realizadas ayudan a identificar áreas de mejora para el modelo como en el procesamiento de los datos. Esto no solo permite validar el éxito del modelo si no también ver que cumpla con los requisitos de la industria en términos de eficiencia y objetividad

La evaluación de las pruebas de campo es tanto un paso técnico como una oportunidad para reflexionar sobre la verdadera capacidad del modelo para integrarse en ámbitos industriales y a los desafíos que se le pueden presentar en inspecciones reales.

3.2 METODOLOGÍA DE EVALUACIÓN

Las pruebas de campo se diseñaron con el fin de medir el modelo de inspección de soldaduras automatizado en un entorno real. Este proceso incluyó la recopilación de datos sacados directamente de piezas soldadas, hacer una inspección visual y luego incorporarlo al modelo de inteligencia artificial para ver su validación

El primer paso fue la selección de piezas soldadas, tanto como soldaduras en buen estado como con defectos. Estas piezas fueron elegidas para incluir diferentes tipos de defectos asegurando que el dataset haya sido entrenado con ellas, y así ver cómo se comporta el modelo en condiciones reales.

Luego, las piezas fueron colocadas sobre una mesa de inspección equipada con una fuente de luz de 2200 lux, que garantiza una iluminación estable, esto le dio un entorno controlado, pero a la misma vez realista, la iluminación es un factor para considerar ya que facilita el proceso de identificar las discontinuidades.

Se realizó una inspección visual sobre las piezas, identificando los defectos presentes en cada una de ellas. Este procedimiento consiguió una referencia para luego ser comparadas con el modelo de IA

Finalmente, se procedió a fotografiar las soldaduras, asegurando así que tenga alta calidad y reflejaran precisión en las características de la pieza. Luego esas imágenes fueron agregadas al modelo de IA y validamos su capacidad de detectar anomalías en condiciones de prueba de campo

3.3 ENFOQUE GENERAL

El enfoque para estas pruebas fue una combinación de una recopilación de imágenes reales, un entorno controlado de inspección y una validación del modelo. Al trabajar en condiciones reales o similares a las de una industria. Este enfoque no solo logró validar la robustez del sistema de inspección visual de soldaduras de forma automatizada, si no que con esto se demostrara que puede ser un proceso que se puede incluir a la industria dando resultados confiables.

3.4 PRUEBAS DE CAMPO

A continuación, se mostrarán las pruebas de campo realizadas, las cuales nos brindó, poner a prueba al modelo de inteligencia artificial ante la situación más semejante a la que se puede dar en un entorno industrial, demostrando así que su desempeño pueda ser capaz de ser utilizado como un proceso industrial.

La evaluación se basó en la selección de fotografías que se realizaron durante las pruebas de campo las cuales representan soldaduras las cuales contenían defectos como porosidad, grietas, salpicadura y socavación, también se sacaron imágenes de soldaduras en buen estado para ver su comportamiento en todos los ámbitos en el que el modelo fue entrenado.

Con esto el modelo procesara las imágenes y nos entregara un veredicto el cual se espera que concuerde con la inspección visual hecha previamente y garantizar que el modelo de inspección visual de soldaduras mediante inteligencia artificial sea capaz de identificar y clasificar las anomalías presentes en el cordón de soldadura.

((Solomon 3D, 2021))

3.5 EVALUACIÓN DEL MODELO MEDIANTE PRUEBAS DE CAMPO

1) En este caso durante la inspección visual se asignó que esta soldadura se encontraba en buen estado



*Ilustración 42- Prueba de campo nr.1 - Soldadura en buen estado
Fuente: Elaboración propia*

Imagen DSCN0395.JPG pertenece a: Tipo tensor([1])

*Ilustración 43- Análisis del modelo de Prueba de campo Nr. 1
Fuente: Elaboración propia Google Colab*

El modelo de inteligencia artificial también clasifico esta soldadura como Soldadura en buen estado (Tipo 1). Esto representa la capacidad del modelo para identificar de manera exitosa una soldadura sin discontinuidades

2) En esta prueba, se inspeccionó visualmente la soldadura y se identificó la presencia de porosidad.



Ilustración 44-Prueba de campo Nr.2 – Porosidad
Fuente: Elaboración propia

Imagen DSCN0374.JPG pertenece a: Tipo tensor([3])

Ilustración 45- Análisis del modelo de Prueba de campo Nr.2
Fuente: Elaboración propia Google Colab

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 3, correspondiente a porosidad. Este resultado evidencia la capacidad del modelo para detectar este tipo de discontinuidad específica.

3) En esta prueba, se inspeccionó visualmente la soldadura y se identificó la presencia de porosidad, un defecto caracterizado por pequeñas cavidades o huecos en la superficie del cordón de soldadura.



*Ilustración 46- Prueba de campo Nr 3. Porosidad
Fuente: Elaboración propia*

Imagen DSCN0394.JPG pertenece a: Tipo tensor([3])

*Ilustración 47- Analisis del modelo de Prueba de Campo Nr. 3
Fuente: Elaboración propia Google Colab*

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 3, correspondiente a porosidad. Este resultado demuestra la capacidad del modelo para identificar este tipo de discontinuidad, incluso en condiciones de prueba de campo.

4) En esta prueba, se inspeccionó visualmente la soldadura y se identificó la presencia de porosidad.




*Ilustración 48- Prueba de campo Nr. 4 Porosidad
Fuente: Elaboración propia*

Imagen DSCN0396.JPG pertenece a: Tipo tensor([3])

*Ilustración 49- Analisis del modelo de Prueba de Campo Nr. 4
Fuente: Elaboración propia Google Colab*

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 3, correspondiente a porosidad. Este resultado demuestra la capacidad del modelo para identificar este tipo de discontinuidad, incluso en condiciones de prueba de campo.

5) En este caso, durante la inspección visual realizada en las pruebas de campo, se determinó que la soldadura presentada contenía una socavado en el borde de la soldadura



*Ilustración 50- Prueba de campo Nr. 5 socavación
Fuente: Elaboración propia*

Imagen PB SCV.png pertenece a: Tipo tensor([1])

*Ilustración 51- Análisis del modelo de Prueba de Campo Nr. 5
Fuente: Elaboración propia Google Colab*

El error en la clasificación del modelo podría estar relacionado con la presencia de una sombra en la zona socavada, lo que pudo haber alterado la interpretación de las características visuales por parte de la IA. Este resultado resalta la importancia de considerar condiciones de iluminación adecuadas en futuras pruebas y de mejorar la capacidad del modelo para diferenciar entre sombras y defectos reales en la superficie de la soldadura.

6) En este caso, se hizo una inspección visual y se determinó que esta soldadura contenía agrietamiento a lo largo de la soldadura.



*Ilustración 52-Prueba de campo Nr.6 Agrietamiento
Fuente: Elaboración propia*

Imagen prueba de campo 05.jpeg pertenece a: Tipo tensor([2])

*Ilustración 53-Análisis del modelo de Prueba de Campo Nr. 6
Fuente: Elaboración propia Google colab*

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 2, correspondiente a agrietamiento. Este resultado demuestra la capacidad del modelo para identificar este tipo de discontinuidad, incluso en condiciones de prueba de campo.

7) En este caso, se hizo una inspección visual y se determinó que esta soldadura contenía salpicadura.



*Ilustración 54-Prueba de campo Nr.7 Salpicadura
Fuente: Elaboración propia*

Imagen DCN200134.png pertenece a: Tipo tensor([4])

*Ilustración 55-Análisis del modelo de Prueba de Campo Nr. 7
Fuente: Elaboración propia Google colab*

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 4, correspondiente a salpicadura. Este resultado demuestra la capacidad del modelo para identificar este tipo de discontinuidad, incluso en condiciones de prueba de campo.

8) En este caso, se hizo una inspección visual y se determinó que esta soldadura contenía agrietamiento a lo largo de la soldadura.



*Ilustración 56- Prueba de campo Nro 8 Agrietamiento
Fuente: Elaboración propia*

Imagen prueba de campo 02.jpeg pertenece a: Tipo tensor([2])

El modelo de inteligencia artificial clasificó esta imagen correctamente como Tipo 2, correspondiente a agrietamiento. Este resultado demuestra la capacidad del modelo para identificar este tipo de discontinuidad, incluso en condiciones de prueba de campo.

3.6 ANÁLISIS DE LOS RESULTADOS DE LA PRUEBA DE CAMPO

El análisis de los resultados de la prueba de campo evidencia que el modelo cuenta con la capacidad de identificar correctamente las discontinuidades que se le presenten en soldaduras. En particular, demostró una gran precisión en soldaduras en buen estado y en defectos como porosidad, grieta y salpicadura. Sin embargo, se detectó una importante limitación en detectar socavaciones, donde el modelo clasificó de forma errónea una soldadura con socavación, detectándola como soldadura en buen estado. Este error se supone que es por situaciones de entorno como la presencia de sombras o algún contraste de la imagen, las cuales pueden afectar directamente a la efectividad del modelo.

Los resultados de la prueba de campo indican que, si bien el modelo es capaz de detectar y clasificar las discontinuidades de forma eficiente, su desempeño aún puede ser más mejorado con más entrenamiento o ajustando parámetro, además se recomienda realizar las pruebas en condiciones controladas de iluminación para eliminar la incertidumbre del impacto que pueden ocurrir por factores externos en la clasificación de discontinuidades en soldaduras.

3.7 LIMITACIONES DETECTADAS EN LA PRUEBA DE CAMPO

Durante las pruebas de campo, se identificaron algunas limitaciones que afectan a la precisión del modelo en la detección de discontinuadas de soldaduras, estas cosas impiden el funcionamiento o al menos le bajan a persistencia del modelo comprometiendo su desempeño, a continuación, se detallaran las limitaciones encontradas:

1. Importancia de una Buena Iluminación y un Ángulo de Cámara Adecuado

Uno de los principales influyentes del rendimiento es la calidad de las imágenes. Se capto que las variaciones de la iluminación pueden generar sombras, reflejos o contrastes en la imagen, lo que puede afectar la eficiencia de la identificación de la discontinuidad. Asimismo, el Angulo de captura de la imagen pueden afectar también a la calidad de la imagen. En una imagen de una soldadura que constaba con socavación fueron mal clasificados debidos a la presencia de sombras.

2. Impacto de la Limpieza de la Superficie de la Soldadura

Otro factor relevante son la presencia de impurezas en las superficies de la soldadura. Como residuos o partículas de electrodo pueden dificultar a la identificación de discontinuadas, ya que el modelo puede confundirse

Se determino que una soldadura limpia mejora la capacidad de detección del modelo por lo tanto se recomienda realizar una limpieza de la soldadura antes de capturar la imagen

3. Dependencia del Dataset Utilizado

El modelo de inteligencia artificial ha sido entrenado con un dataset especifico, por lo tanto, el aprendizaje del modelo está sometido directamente a el entrenamiento del dataset

3.8 PROPUESTA DE MEJORA PARA LAS LIMITACIONES DEL MODELO

Para mejorar las limitaciones detectadas anteriormente, podría ser necesario la implementación de estrategias que optimicen la calidad e las imágenes, lo cual fortalecería el desempeño de detección del modelo, una de estas propuestas es la estandarización de condiciones de captura de imágenes, como asegurarse de una buena iluminación.

Otro aspecto para mejorar la consistencia del modelo de inspección de soldaduras es un procedimiento de limpieza previo antes de la captura de imágenes. Al hacer esto se eliminan impurezas, oxido y residuos lo cual permita al modelo que detecte los modelos de forma más precisa al disminuir la probabilidad de confusión del modelo debido a la posibilidad de confundir residuos con alguna discontinuidad

Finalmente, siempre se recomendara expandir cada vez más el dataset utilizado para el entrenamiento del modelo, ya que mientras más ejemplos de soldaduras, mayor será la capacidad del modelo de detectar discontinuidades siempre cuando las imágenes sean de calidad, también se podrían diversificar las imágenes de soldadura en otras condiciones ambientales para que el modelo tenga una capacidad de detección más amplia, además de la implementación de más técnicas de aumento de datos y ajusten de los parámetros con el fin de mejorar la optimización del modelo, todo esto contribuirá a fortalecer el desempeño del modelo y reducir sus dependencias específicas.

3.9 REFLEXIÓN FINAL DE LAS PRUEBAS DE CAMPO

Las pruebas de campo han sido un proceso clave ya que permitió una evaluación del rendimiento del sistema en un entorno real, las pruebas de campo demostrando que el modelo cuenta con la capacidad de identificar de manera correcta cuando una soldadura está en buen estado y cuando cuenta con alguna discontinuidad. Sin embargo, también se detectaron algunas limitaciones, especialmente iluminación y ángulos de imagen incorrectos

Estos resultados han dado lugar a una reflexión sobre la importancia de la calidad del dataset, una correcta preparación del entorno en el cual se hará la inspección, una mejora del dataset y una optimización del modelo, todo esto son aspectos para mejorar ya que harán de un modelo con mayor precisión y robustez.

A pesar de las dificultades, con el resultado de las pruebas de campo ha demostrado que la inteligencia artificial en el ámbito de inspección de soldaduras es un proceso viable y que cuanto, con un gran potencial, hay aspectos que se deben mejorar, pero sigue siendo funcional y es un gran paso a futuras mejoras que permitan un aun mayor funcionamiento en la detección de discontinuidades en uniones soldadas.

CONCLUSIÓN

El desarrollo de este proyecto ha permitido la implementación de un modelo de inteligencia artificial basado en visión computacional para la inspección visual de soldaduras, alineado con normativas internacionales y diseñado para mejorar la detección de discontinuidades en entornos industriales. A través de un proceso estructurado de diseño, entrenamiento y validación, se logró consolidar un sistema capaz de identificar distintos tipos de defectos en soldaduras, optimizando la automatización del proceso de inspección y reduciendo la dependencia de evaluaciones exclusivamente humanas.

Los resultados obtenidos reflejan un avance significativo en la capacidad del modelo para clasificar soldaduras en buen estado y detectar anomalías, alcanzando una efectividad global del **87%** en la identificación de defectos. La validación del sistema demostró que es capaz de reconocer con alta precisión discontinuidades como porosidad y salpicaduras, aunque persisten ciertas dificultades en la detección de defectos como socavación, especialmente cuando existen variaciones en la iluminación o en la limpieza de la superficie de la soldadura. Estas observaciones resaltan la importancia de seguir optimizando el modelo a través de la ampliación y diversificación del dataset, así como la implementación de técnicas avanzadas de procesamiento de imágenes.

Las pruebas de campo permitieron evaluar el desempeño del sistema en condiciones más cercanas a su aplicación real, lo que permitió identificar tanto sus fortalezas como sus limitaciones. La influencia de factores externos, como la iluminación y la calidad de la imagen, evidenció que la efectividad del modelo puede verse comprometida en escenarios no controlados, lo que hace necesario establecer protocolos estandarizados de captura de imágenes y considerar técnicas de preprocesamiento para minimizar estos efectos adversos. Además, se identificó la dependencia del modelo respecto a la cantidad y calidad de los datos utilizados en su entrenamiento, lo que sugiere la necesidad de seguir incorporando imágenes más representativas para mejorar su capacidad de generalización.

En conclusión, si bien el modelo desarrollado representa un avance significativo en la automatización de la inspección visual de soldaduras, aún existen oportunidades de mejora que permitirían incrementar su precisión y aplicabilidad en entornos industriales reales. La optimización del dataset, el ajuste de los parámetros del modelo y la integración de nuevas estrategias de aprendizaje son aspectos clave para su evolución. Con futuras mejoras, esta tecnología podrá consolidarse como una herramienta confiable y eficaz, contribuyendo a la estandarización y modernización de los procesos de control de calidad en soldaduras, optimizando tiempos de inspección y reduciendo la subjetividad en la detección de discontinuidades.

BIBLIOGRAFIA

American Welding Society (AWS). (2020). D1.1/D1.1M: Structural Welding Code – Steel. Miami, FL: AWS.

British Standards Institution (BSI). (2016). BS EN ISO 13018: Non-destructive Testing – Visual Testing – General Principles. London, UK: BSI.

Szeliski, R. (2021). Computer Vision: Algorithms and Applications. Springer.

Google Research. (2023). Google Colaboratory. Google Colab. <https://colab.research.google.com>

Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
Shutterstock imágenes de soldadura <https://www.shutterstock.com/es/search/defectos-de-soldadura>

Google Imágenes

Labellerr. (2024). Transforming Industrial Maintenance: The Power of Computer Vision. Recuperado de https://www.labellerr-com.translate.goog/blog/transforming-industrial-maintenance-the-power-of-computer-vision/?x_tr_sl=en&x_tr_tl=es&x_tr_hl=es&x_tr_pto=tc

Cruz, Y. J., Rivas, M., Quiza, R., Beruvides, G., & Haber, R. E. (2020). Computer Vision System for Welding Inspection of Liquefied Petroleum Gas Pressure Vessels Based on Combined Digital Image Processing and Deep Learning Techniques. Sensors, 20(16), 4505. <https://doi.org/10.3390/s20164505>

Alsarhan, A., Al-Khazraji, H., Jassim, S., Al-Bayati, A., & Al-Khafaji, A. (2024). Recent Advances in Convolutional Neural Networks: Architectures, Training, and Applications. Sensors, 25(1), 25. <https://doi.org/10.3390/s25010025>

Solomon 3D. (2021). AI Detection of Welding Defects. Recuperado de <https://www.solomon-3d.com/case-studies/solvision/ai-detection-of-welding-defects/>

Omdena. (2023). Enhancing Welding Processes Using Machine Learning-Based Defect Analysis. <https://www.omdena.com/projects/enhancing-welding-processes-using-machine-learning-based-defect-analysis>

MathWorks. (s.f.). ¿Qué son las redes neuronales convolucionales? Recuperado de <https://la.mathworks.com/discovery/convolutional-neural-network.html>

ANEXOS




Ilustración 57- Anexo 1 % precisión
Fuente: Elaboración propia Google Colab




Ilustración 58- Anexo 2 Paquete perdida
Fuente : Elaboración propia Google Colab