

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

DESARROLLO DE UN MODELO DE INSPECCIÓN EN UNIONES SOLDADAS
MEDIANTE EL USO DE LÍQUIDOS PENETRANTES, INTELIGENCIA ARTIFICIAL Y
VISIÓN COMPUTACIONAL

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

Alumno: Esteban Ignacio Contreras Arancibia

Profesor Guía: Mg. Ing. Pablo Andrés Duque Ramírez

DEDICATORIA

Este logro es el resultado de años de esfuerzo y aprendizaje. Pero ningún camino se recorre solo, y en este trayecto he tenido la suerte de contar con el amor, el apoyo y la confianza de mi familia, además de una persona muy especial en mi vida. A todos ellos les dedico este éxito con todo mi corazón.

A mi madre, Carolina Arancibia, porque sin su amor incondicional, su valentía y sus enseñanzas, este sueño no habría sido posible. Gracias por cada palabra de aliento, cada consejo y cada sacrificio que hiciste para que yo pudiera llegar hasta aquí. Eres mi mayor ejemplo de amor verdadero.

A mi padre, Albert Contreras, por ser un pilar en mi vida. Gracias por enseñarme el valor del esfuerzo, la disciplina y la perseverancia. Tus palabras y tu ejemplo de trabajo constante han sido una inspiración en cada paso de este camino.

A mi hermano mayor, Albert Contreras, porque siempre has sido un modelo que seguir para mí. Aprecio tus consejos y por demostrarme que con dedicación todo es posible. Tu ejemplo me ha impulsado a seguir adelante.

A mi hermano menor, Vicente Contreras, porque, aunque eres el más joven, has sido una gran inspiración para mí. Ver cómo creces y superas tus propios desafíos me llena de orgullo. Gracias por tu cariño.

A mi novia, Emily Díaz, porque has estado a mi lado en todo este proceso, celebrando mis logros y apoyándome en los momentos más duros. Gracias por tu paciencia, por creer en mí incluso cuando yo mismo dudaba.

Esto no es el final del camino, sino el comienzo de algo aún más grande. Lo que he logrado hasta ahora es solo la base de todo lo que quiero construir. Todavía hay muchos sueños por cumplir, metas por alcanzar y desafíos por superar. Este es solo el inicio de un futuro lleno de oportunidades.

Con todo mi cariño,

Esteban Ignacio Contreras Arancibia

RESUMEN

KEYWORDS: INTELIGENCIA ARTIFICIAL, VISIÓN COMPUTACIONAL, LÍQUIDOS PENETRANTES, EVALUACIÓN DE SOLDADURAS, INDUSTRIA 4.0.

El presente trabajo tiene como objetivo el desarrollo de un modelo automatizado para la inspección de uniones soldadas utilizando líquidos penetrantes, inteligencia artificial (IA) y visión computacional. La industria contemporánea se topa con restricciones en los métodos de revisión manual, tales como la variabilidad en los resultados, largos periodos de evaluación y la tendencia a fallos humanos. Para enfrentar estos retos, este proyecto sugiere la implementación de tecnologías de vanguardia que incrementan la exactitud en un 40% en comparación con la inspección manual, disminuyen los periodos de evaluación en un 80% y mejoran la rastreabilidad del proceso de inspección (Tulip, s.f.).

El modelo producido utiliza Redes Neuronales Convolucionales (CNN), un método que la Inteligencia Artificial a menudo utiliza para el estudio de imágenes y la categorización de patrones complejos. Estas redes se generaron a partir de un dataset de más de 100 imágenes de soldaduras previamente procesadas, consiguiendo así la identificación automática de discontinuidades esenciales como fisuras, porosidades y socavaciones. Para garantizar el cumplimiento de estándares de calidad y seguridad, se establecieron normas internacionales como ASTM E165/E165M e ISO 3452, las cuales establecen pautas técnicas para la revisión con líquidos penetrantes.

El desarrollo del modelo incluyó diversas etapas clave, desde el diseño de una arquitectura óptima, preprocesamiento y normalización de imágenes, hasta su entrenamiento en entornos computacionales avanzados utilizando herramientas como Google Colab. Se realizó su evaluación a través de indicadores de rendimiento como precisión, sensibilidad y especificidad, logrando un desempeño destacado con una precisión del 80% en pruebas de clasificación en entornos industriales reales. Además, el uso de la matriz de confusión simplificó la detección de puntos fuertes y áreas para optimizar.

Con los principios de la Industria 4.0, este modelo fomenta la adopción de tecnologías emergentes, impulsando la automatización y digitalización de los procesos de control de calidad en soldaduras. Su integración no solo mejora la inspección, sino que también representa un avance significativo en la transformación digital del sector industrial.

ÍNDICE

RESUMEN.....	2
INTRODUCCIÓN	12
CAPÍTULO 1: ANÁLISIS DE NORMAS INTERNACIONALES Y TECNOLOGÍAS PARA LA INSPECCIÓN CON LÍQUIDOS PENETRANTES	14
1.1. INCORPORACIÓN DE TECNOLOGÍAS AVANZADAS EN LA INSPECCIÓN DE LÍQUIDOS PENETRANTES	15
1.2. TECNOLOGÍAS RELEVANTES	16
1.2.1. SISTEMAS AUTOMATIZADOS DE APLICACIÓN DE LÍQUIDOS PENETRANTES	16
1.2.2. VISIÓN COMPUTACIONAL.....	17
1.2.3. SOFTWARE PARA ANÁLISIS DE IMÁGENES	17
1.2.4. INTEGRACIÓN DE TECNOLOGÍAS EN EL PROYECTO.....	18
1.3. MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN	19
1.3.1. MODELOS DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DEFECTOS EN SOLDADURAS	19
1.3.2. APLICACIÓN DEL MODELO DE CONFUSIÓN EN LA EVALUACIÓN DEL SISTEMA	21
1.3.3. IMPORTANCIA DEL MODELO DE CONFUSIÓN EN EL PROYECTO	22
1.3.4. ESTRATEGIAS DE OPTIMIZACIÓN DEL DESEMPEÑO DEL MODELO DE IA	22
1.4. INSPECCIÓN CON LÍQUIDOS PENETRANTES EN ENSAYOS NO DESTRUCTIVOS (END).....	23
1.4.1. ASTM E165/E165M: MÉTODOS Y PROCEDIMIENTOS.....	23
1.4.2. ISO 3452: COMPATIBILIDAD Y SENSIBILIDAD DEL MÉTODO	24
1.4.3. TIPOS DE DISCONTINUIDADES DETECTABLES CON LÍQUIDOS PENETRANTES	25
1.4.4. VENTAJAS Y APLICACIONES DE LA INSPECCIÓN CON LÍQUIDOS PENETRANTES	27
1.4.5. ESTANDARIZACIÓN Y GARANTÍA DE CALIDAD	27

1.5. PROCEDIMIENTOS PARA LA INSPECCIÓN DE SOLDADURAS CON LÍQUIDOS PENETRANTES	28
1.5.1. PREPARACIÓN DE LA SUPERFICIE PARA LA INSPECCIÓN	30
1.5.2. APLICACIÓN DEL LÍQUIDO PENETRANTE EN LA SUPERFICIE DE INSPECCIÓN	30
1.5.3. ELIMINACIÓN DEL EXCESO DE LÍQUIDO PENETRANTE	31
1.5.4. APLICACIÓN DEL REVELADOR.....	32
1.5.5. CONDICIONES DE ILUMINACIÓN Y SU IMPACTO EN LA INSPECCIÓN CON LÍQUIDOS PENETRANTES	32
1.5.6. CONSIDERACIONES AMBIENTALES	33
1.5.7. REGISTRO Y TRAZABILIDAD DE RESULTADOS DE LA INSPECCIÓN	34
1.6. NORMATIVAS INTERNACIONALES PARA LA INSPECCIÓN DE LÍQUIDOS PENETRANTES	34
1.6.1. APLICACIÓN DE LA NORMA ASTM E165/E165M EN LA INSPECCIÓN	35
1.6.2. REGULACIONES DE LA NORMA ISO 3452 EN LA INPECCIÓN DE SOLDADURAS	36
1.6.3. COMPARACIÓN DE NORMAS: ISO 3452 VS. ASTM E165.....	37
1.6.4. CONSIDERACIONES DE LA NORMA AWS D1.1 EN LA INSPECCIÓN DE SOLDADURAS.....	37
1.6.5. ALCANCE Y APLICABILIDAD DE LAS NORMAS EN INSPECCIÓN DE SOLDADURAS.....	38
1.6.6. CRITERIOS DE ACEPTACIÓN DE DEFECTOS SEGÚN NORMAS INSTERNACIONALES	39
CAPÍTULO 2: DISEÑO Y DESARROLLO DEL MODELO DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DISCONTINUIDADES EN SOLDADURAS.....	40
2.1. ESTRATEGIA TECNOLÓGICA PARA LA INSPECCIÓN AUTOMATIZADA DE SOLDADURAS	41
2.2. DISEÑO E IMPLEMENTACIÓN DEL MODELO DE INTELIGENCIA ARTIFICIAL PARA LA INSPECCIÓN DE SOLDADURAS	41
2.2.1. APLICACIÓN DE VISIÓN COMPUTACIONAL EN LA INSPECCIÓN DE SOLDADURAS.....	41

2.2.2. ARQUITECTURA DEL MODELO BASADO EN REDES NEURONALES CONVOLUCIONALES (CNN).....	42
2.2.3. SELECCIÓN Y CONFIGURACIÓN DE SENSORES Y EQUIPOS DE CAMARA	43
2.3. DISEÑO DEL MODELO Y CONFIGURACIÓN DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	44
2.3.1. ARQUITECTURA DEL MODELO DE IA	44
2.3.2. FLUJO DE DATOS EN EL SISTEMA Y PROCESAMIENTO EN EL SISTEMA	45
2.3.3. IMPLEMENTACIÓN DE GOOGLE COLAB Y GOOGLE DRIVE	46
2.4. PROCESO DE ENTRENAMIENTO Y VALIDACIÓN DEL MODELO.....	48
2.4.1. ETAPAS DEL ENTRENAMIENTO DEL MODELO DE IA	49
2.4.2. CONDICIONES Y PROCESAMIENTO DE IMÁGENES	50
2.4.3. ESTRATEGIAS DE ENTRENAMIENTO Y AJUSTE DEL MODELO .	52
2.4.4. EVALUACIÓN DEL DESEMPEÑO MEDIANTE MÉTRICAS DE RENDIMIENTO	55
2.5. ANÁLISIS DEL MODELO DE CONFUSIÓN Y MÉTRICAS DE EVALUACIÓN	57
2.5.1. ITERACIONES Y ALCANCE DE PRECISIÓN DEL MODELO	59
2.5.2. EVALUACIÓN DEL DESEMPEÑO Y COMPARACIÓN CON MÉTODOS TRADICIONALES.....	60
2.5.3. CONSIDERACIONES FINALES SOBRE LA EVALUACIÓN DEL MODELO	62
2.6. OPTIMIZACIÓN Y AJUSTES DEL MODELO DE IA	63
2.6.1. TÉCNICAS DE REGULARIZACIÓN Y MEJORA DEL RENDIMIENTO	63
2.6.2. ESTRATEGIA DE AUMENTO DE DATOS PARA MEJORAR GENERALIZACIÓN.....	64
2.7. LIMITACIONES Y DESAFÍOS TÉCNICOS EN LA INSPECCIÓN AUTOMATIZADA	64
2.7.1. VARIABILIDAD DE LOS ÁNGULOS DE CAPTURA Y SU IMPACTO EN LA PRECISIÓN.....	65

2.7.2. SENSIBILIDAD DEL MODELO A LAS CONDICIONES DE ILUMINACIÓN	65
2.7.3. LIMITACIONES EN EL RECONOCIMIENTO DE IMÁGENES EN BLANCO Y NEGRO.....	66
CAPÍTULO 3: EVALUACIÓN DEL MODELO EN PRUEBAS DE CAMPO Y ESCENARIOS INDUSTRIALES	69
3.1. PREPARACIÓN PARA LAS PRUEBAS DE CAMPO.....	70
3.1.1. SELECCIÓN DE ESCENARIOS INDUSTRIALES PARA LA EVALUACIÓN DEL MODELO.....	70
3.1.2. CONFIGURACIÓN DEL EQUIPO Y SOFTWARE DE INSPECCIÓN.	70
3.1.3. COMPARACIÓN ENTRE ENTRENAMIENTO Y PRUEBAS DE CAMPO	71
3.2. PROCEDIMIENTO DE EVALUACIÓN DEL MODELO.....	72
3.2.1. MÉTODOS DE CAPTURA DE IMÁGENES EN AMBIENTES INDUSTRIALES.....	73
3.2.2. DISCONTINUIDADES SIMULADAS Y REALES EVALUADAS EN LAS PRUEBAS	73
3.3. ANÁLISIS DE RESULTADOS Y VALIDACIÓN DEL MODELO.....	74
3.3.1. EVALUACIÓN DE LA MATRIZ DE CONFUSIÓN.....	74
3.3.2. CASOS EXITOSOS Y LIMITACIONES IDENTIFICADAS.....	76
3.3.3. AJUSTES IMPLEMENTADOS TRAS LA EVALUACIÓN EXPERIMENTAL	77
3.3.4. MEJORAS EN LA DETECCIÓN DE DISCONTINUIDADES.....	77
3.3.5. COMPARACIÓN ENTRE EL MODELO ENTRENADO Y LOS RESULTADOS EN PRUEBAS DE CAMPO.....	78
3.4. COMPARACIÓN CON MÉTODOS TRADICIONALES DE INSPECCIÓN	78
3.4.1. VENTAJAS DEL MODELO IA FRENTE A LA INSPECCIÓN MANUAL	79
3.4.2. EFICIENCIA EN EL USO DE TIEMPO Y RECURSOS.....	80
3.4.3. COMPARACIÓN CON OTROS MÉTODOS NO DESTRUCTIVOS.....	82
3.5. APLICABILIDAD INDUSTRIAL DE LA IA EN LA INSPECCIÓN DE SOLDADURAS.....	83

CONCLUSIONES Y RECOMENDACIONES.....	84
BIBLIOGRAFÍA.....	85
ANEXOS	86
Anexo 1: ENTRENAMIENTO DE UN MODELO CNN	86
Anexo 2: ANÁLISIS DE TIPOS DE DEFECTOS EN UNIONES SOLDADAS.....	88
Anexo 3: OPTIMIZACIÓN DE UN MODELO DE VISIÓN COMPUTACIONAL.....	91

ÍNDICE DE ILUSTRACIONES

Ilustración 1-1 "Redes Neuronales Convolucionales (CNN)"	20
Ilustración 1-2 "Matriz de Confusión"	21
Ilustración 1-3 "Ensayo con Porosidad"	25
Ilustración 1-4 "Ensayo con Grietas"	25
Ilustración 1-5 "Ensayo con Socavaciones"	26
Ilustración 1-6 "Ensayo Incompleto".....	26
Ilustración 1-7 "Limpiador SKC-S"	30
Ilustración 1-8 "Probeta con penetrante".....	31
Ilustración 1-9 "Probeta limpia de exceso de penetrante".....	31
Ilustración 1-10 "Resultado de ensayo"	32
Ilustración 2-1 "Resultado de Modelo IA 89%"	60
Ilustración 2-2 "Matriz de Confusión con Imágenes Blanco y Negro 49%"	67
Ilustración 3-1 "Matriz de Confusión Resultado 80%"	74

ÍNDICE DE DIAGRAMAS

DIAGRAMA 1-1 "Proceso de Inspección con Líquidos Penetrantes"	29
DIAGRAMA 2-1 "Proceso de Entrenamiento y Validación"	48
DIAGRAMA 3-1 "Procedimiento de Evaluación del Modelo"	72

ÍNDICE DE GRÁFICAS

Gráfico 2-1 "Resultados de Accuracy %"	56
Gráfico 2-2 "Desempeño del Modelo IA"	59
Gráfico 2-3 "Efecto de la Iluminación en la Precisión del Modelo IA"	66
Gráfico 3-1 "Comparación en Tiempos de Inspección"	80

ÍNDICE DE TABLAS

Tabla 1-1 "Iluminación requerida según Norma ISO 3452-1"	33
Tabla 1-2 "Comparación de normas: ISO 3452 vs ASTM E165	37
Tabla 2-1 "Estrategia de Aumento"	64
Tabla 3-1 "Parámetros del Modelo"	71
Tabla 3-2 "Comparativa de Desempeño entre Modelos"	78
Tabla 3-3 "Comparativa de Desempeño entre Métodos de Inspección	79
Tabla 3-4 "Comparativa Cantidad Piezas Analizadas"	81
Tabla 3-5 "Comparativa de Análisis por Método"	81

ÍNDICE DE CÓDIGO

Código 2-1 "Red Neuronal CNN en Pytorch"	44
Código 2-2 "Preprocesamiento y Carga de Datos"	46
Código 2-3 "Entorno Google Drive en Colab Google"	47
Código 2-4 "Preparación del Dataset: Transformaciones y DataLoader"	50
Código 2-5 "Parámetros de Imágenes Visión Computacional"	51
Código 2-6 "Aumento de Datos: Rotaciones, Espejos y Escalado en Imágenes"	52
Código 2-7 "Implementación de Red Neuronal Convolutiva con Capa Totalmente Conectada Ajustada"	53
Código 2-8 "Entrenamiento de Modelo de IA con CUDA y PyTorch para Visión Computacional"	54
Código 2-9 "Matriz de Confusión para Evaluar la Precisión de un Modelo de Clasificación"	58

SIGLAS Y SIMBOLOGÍA

SIGLAS

AI:	Artificial Intelligence (Inteligencia Artificial).
ASTM:	American Society for Testing and Materials.
AWS:	American Welding Society.
CNN:	Convolutional Neural Networks (Redes Neuronales Convolucionales).
END:	Ensayos No Destructivos.
ML:	Machine Learning (Aprendizaje Automático).

TÉRMINOLOGÍA

Discontinuidad:	Irregularidad en un material que no compromete su integridad, pero puede convertirse en un defecto si supera los criterios normativos.
Defecto:	Discontinuidad que excede los límites permitidos por normativas como ISO 3452-2 o ASTM E165/E165M , afectando la seguridad estructural.
Visión Computacional:	Rama de la IA que analiza imágenes para la detección automática de defectos en inspecciones industriales.
Redes Neuronales Convolucionales (CNN):	Algoritmos de aprendizaje profundo que identifican y clasifican discontinuidades en soldaduras a partir de imágenes.
Modelo de Confusión:	Método de evaluación de IA que mide la precisión del modelo comparando sus predicciones con valores reales.
Falsos Positivos (FP):	Casos en los que se detecta erróneamente un defecto en una superficie sin discontinuidades.
Falsos Negativos (FN):	Defectos no detectados por el sistema a pesar de estar presentes en la soldadura.

INTRODUCCIÓN

En la actualidad, inspeccionar las soldaduras es muy importante para asegurarse de que las estructuras sean seguras y no fallen, ya sea en tubos o en otras uniones. Estas revisiones ayudan a evitar problemas que podrían detener la producción o poner en riesgo la seguridad.

Para impulsar tecnologías como la inteligencia artificial (IA) y la visión computacional, se está generando una transformación significativa en el estudio de las soldaduras. Estas herramientas facilitan la identificación y categorización automática de discontinuidades, mejorando la rapidez, precisión y seguimiento de los resultados.

Este estudio integra estándares reconocidos, como la ASTM E165/E165M y la ISO 3452, con modelos de inteligencia artificial. Se llevará a cabo un análisis detallado de estas normativas, se evaluarán diferentes modelos de inteligencia artificial. Este enfoque ayuda que el sistema sea aplicable en entornos industriales.

El programa usará visión computacional y redes neuronales (CNN) para analizar imágenes de soldaduras, detectando y clasificando automáticamente defectos según las normas. Estas redes poseen la capacidad de detectar patrones complejos, serán formadas con datos concretos y evaluadas para mejorar su precisión.

Esta solución generará un impacto significativo en el sector, acelerando las inspecciones y mejorando su exactitud, al mismo tiempo que reduce las equivocaciones humanas. Al optimizar los procesos de inspección y fomentar el uso de tecnologías avanzadas, este trabajo contribuye a la modernización y digitalización de la inspección industrial.

OBJETIVO GENERAL

Desarrollar un modelo automatizado de inspección en uniones soldadas con el ensayo de líquidos penetrantes, empleando inteligencia artificial y visión computacional, mejorando en la precisión de identificación de las discontinuidades.

OBJETIVOS ESPECÍFICOS

- Analizar las normas internacionales para líquidos penetrante, identificando las tecnologías relevantes para el desarrollo del modelo de inteligencia artificial y visión computacional.
- Diseñar una arquitectura para el modelo de IA y visión computacional, integrando técnicas y tecnologías para la detección de discontinuidad en las superficies, considerando las normas internacionales para líquidos penetrantes.
- Evaluar la funcionalidad del modelo en pruebas de campo en diversos escenarios industriales, verificando su capacidad detectando discontinuaciones en condiciones reales.

**CAPÍTULO 1: ANÁLISIS DE NORMAS INTERNACIONALES Y TECNOLOGÍAS
PARA LA INSPECCIÓN CON LÍQUIDOS PENETRANTES**

1.1. INCORPORACIÓN DE TECNOLOGÍAS AVANZADAS EN LA INSPECCIÓN DE LÍQUIDOS PENETRANTES

En la industria, la inspección con líquidos penetrantes se utiliza para detectar indicaciones en la superficie. De acuerdo con la norma (ISO 3452-1, 2023), este procedimiento opera debido a que el líquido se infiltra en minúsculas fisuras y, mediante el uso de un revelador, facilita la detección de los defectos. Es un proceso esencial en áreas donde la calidad de las soldaduras es de vital relevancia.

A pesar de su eficacia, su eficacia se basa principalmente en la percepción humana, lo que puede provocar fallos del 15-20% debido al agotamiento visual, la subjetividad y el entorno laboral (Inspenet, 2023). Además, es un procedimiento bastante pausado, dado que el estudio de cada elemento puede durar entre 5 y 10 minutos, lo que disminuye la productividad en zonas de gran producción (Tulip, s.f.) .

La fusión de inteligencia artificial (IA) y visión computacional optimiza este proceso al automatizar la detección y clasificación de defectos, reduciendo la variabilidad y aumentando la precisión. El estudio ha demostrado que los modelos basados en redes neuronales convolucionales (CNN) tienen la habilidad de detectar discontinuidades con una exactitud que supera el 90%, superando los métodos tradicionales (learning, 2018) . Además, la visión computacional permite identificar defectos de hasta 0.05 mm, optimizando la detección en comparación con la inspección visual (Vision, s.f.).

La automatización también reduce el tiempo de inspección en búsqueda de indicaciones en un 50%, permitiendo inspecciones a defectos en menos de 5 minutos por pieza para dar resultado (Sanders, 2020). Además, la digitalización de los datos facilita la trazabilidad y el cumplimiento de normativas, mejorando la gestión de calidad. Se estima que en los próximos cinco años más del 70% de las industrias adoptarán IA en sus procesos de inspección, consolidando la transformación digital y la Industria 4.0 (Mundial, 2023) .

1.2. TECNOLOGÍAS RELEVANTES

La adopción de tecnologías de punta en la revisión con líquidos penetrantes no solo perfecciona los procedimientos existentes, sino que también incrementa la exactitud, reproducibilidad y eficacia en la identificación de anomalías superficiales (Sanders, 2020). A pesar de su eficacia, la revisión manual se basa principalmente en el criterio del inspector, lo que implica un riesgo de equivocación y variabilidad en los resultados (Baldev, 2002). En este proyecto, se incorporan instrumentos que facilitan la automatización y la incorporación de inteligencia artificial (IA) y visión computacional, garantizando un método más justo, exacto y fiable para identificar fallos en las soldaduras.

La implementación de estas tecnologías constituye un progreso importante de los ensayos no destructivos (END), dado que facilita la optimización de la rastreabilidad de los datos y disminuye el tiempo necesario para detectar defectos (ISO 3452-1, 2023). Se presentan a continuación las tecnologías más significativas utilizadas en este modelo.

1.2.1. SISTEMAS AUTOMATIZADOS DE APLICACIÓN DE LÍQUIDOS PENETRANTES

Es esencial la automatización del procedimiento de aplicación del penetrante y el revelador para asegurar la uniformidad en la inspección y minimizar las variaciones vinculadas a los procedimientos manuales. En una revisión convencional, el volumen de líquido vertido, el período de exposición y las condiciones para eliminar el sobrante son totalmente determinantes del operador, lo que puede provocar discrepancias entre una valoración y otra.

Los sistemas automatizados facilitan la supervisión exacta de estos parámetros, garantizando que cada revisión se lleve a cabo conforme a las normas establecidas. (ASTM International E165/E165M, 2020) y (ISO 3452-1, 2023). Estos documentos controlan elementos esenciales como el período de exposición del líquido penetrante, los procedimientos de eliminación y las normas para tolerar discontinuidades, asegurando una valoración exacta y normalizada. Adicionalmente, la automatización ayuda a disminuir el tiempo de inspección para buscar indicaciones, lo cual repercute directamente en la eficacia operacional. Aunque un procedimiento manual de inspección puede llevar entre 10 y 15 minutos por pieza, los sistemas automatizados tienen la capacidad de buscar indicaciones en la mitad del tiempo, lo que conlleva a un incremento notable de la productividad en ambientes industriales de alta demanda (Sanders, 2020).

1.2.2. VISIÓN COMPUTACIONAL

El proyecto se basa en la tecnología de la visión informática, ya que simplifica la captura y análisis de imágenes de alta resolución de las superficies que se están investigando. Esta tecnología ha sido ampliamente utilizada en el estudio industrial, evidenciando su capacidad para detectar fallos con gran precisión mediante algoritmos avanzados de análisis de imágenes (Köhler, 2021). La inteligencia artificial y la visión computacional potencian la confiabilidad de la inspección, disminuyendo la dependencia del juicio humano y mejorando la identificación de irregularidades.

El uso de cámaras especializadas y software para el análisis de imágenes puede mejorar la detección de irregularidades, incluso en situaciones de iluminación estrictas. Según la norma (ISO 3452-1, 2023), para las inspecciones se debe tener un nivel de luz blanca de 1000 lux, aunque valores superiores pueden aumentar la visibilidad y la precisión de la evaluación. Esto asegura que las fotografías tomadas sean de excelente calidad y faciliten una valoración más exacta de los fallos en la superficie de la soldadura, complementando la revisión visual convencional.

Investigaciones actuales han evidenciado que los modelos de redes neuronales convolucionales (CNN) utilizadas en la visión computacional tienen la capacidad de lograr precisiones que superan el 90% en la identificación de discontinuidades en soldaduras (Smith, 2018). Esto constituye un avance importante en comparación con la revisión manual, que presenta un margen de error del 15-20% debido a elementos como el cansancio ocular, la variabilidad de la luz y la subjetividad en la interpretación de los hallazgos (Inspenet, 2023). Además de incrementar la exactitud, la visión computacional facilita la automatización de la categorización de defectos, lo que mejora el proceso de trabajo y disminuye la carga laboral del equipo de inspección. Esta tecnología es fundamental para alcanzar un modelo de inspección más fiable, repetible y en concordancia con los fundamentos de la Industria 4.0 (Sanders, 2020).

1.2.3. SOFTWARE PARA ANÁLISIS DE IMÁGENES

El estudio automático de fotografías es otro elemento esencial del modelo de inspección. Históricamente, el inspector es quien interpreta las señales encontradas en una revisión con líquidos penetrantes, lo que implica un elevado nivel de subjetividad y complica la normalización de los hallazgos (Sanders, 2020).

El uso de programas especializados en análisis de imágenes facilita la identificación, evaluación y categorización de manera equitativa de las discontinuidades (Köhler, 2021). Estos programas han sido creados para administrar grandes cantidades de imágenes, utilizando

algoritmos que identifican anomalías basándose en su tamaño, forma y localización. Adicionalmente, este programa cumple con las normas de la (ISO 3452-1, 2023), que define criterios para la valoración de discontinuidades a través de técnicas cuantitativas. Al suprimir la subjetividad del procedimiento, se consigue una revisión más exacta y repetible, lo que incrementa la fiabilidad del diagnóstico y disminuye la probabilidad de equivocaciones en la interpretación de los hallazgos (Smith, 2018).

Otra ventaja significativa del análisis. Cada evaluación se almacena en una base de datos digital, lo que permite la elaboración de informes exhaustivos y la simplificación de las auditorías.

1.2.4. INTEGRACIÓN DE TECNOLOGÍAS EN EL PROYECTO

La fusión de automatización, visión informática y análisis sofisticado de imágenes facilita el enfrentamiento de las principales restricciones de la revisión manual, disminuyendo la subjetividad en la interpretación y potenciando la repetibilidad de los resultados.

Uno de los desafíos más importantes en la revisión de soldaduras es garantizar que el método respete las normativas internacionales. En estas situaciones, los sistemas de inspección apoyados en inteligencia artificial promueven una normalización más eficiente, disminuyendo las equivocaciones humanas. De acuerdo con (Sanders, 2020) *“la implementación de tecnologías de vanguardia en la inspección industrial ha impulsado el incremento de la eficiencia en las operaciones y la excelencia en la administración de procesos, mejorando la identificación de fallos estructurales en la producción contemporánea”*.

Mediante la utilización de Inteligencia Artificial y visión informática, se consigue un sistema de inspección sumamente eficaz, escalable y flexible para diversas circunstancias industriales. Asimismo, su puesta en marcha promueve el cambio hacia la Industria 4.0, incentivando la digitalización y automatización de las pruebas no destructivas.

1.3. MODELOS DE IA EXISTENTES Y USO DEL MODELO DE CONFUSIÓN

La implementación de la inteligencia artificial (IA) en la revisión de soldaduras ha revolucionado los procedimientos convencionales, posibilitando la identificación automática, exacta y eficaz de anomalías superficiales. Dado que los algoritmos de inteligencia artificial tienen la habilidad de examinar grandes cantidades de datos y detectar patrones, su implementación en pruebas no destructivas (END) resulta imprescindible (Köhler, 2021).

En estas investigaciones, los métodos más frecuentemente empleados incluyen las Redes Neuronales Convolucionales (CNN), las Máquinas de Soporte Vectorial (SVM) y los Bosques Aleatorios. No obstante, la selección del modelo se basa en la naturaleza del proyecto y sus metas. En este escenario, las CNN resultan perfectas ya que poseen la habilidad de examinar imágenes e identificar patrones complejos, lo que simplifica la identificación de fallos en las soldaduras.

El estudio ha demostrado que los modelos basados en redes neuronales convolucionales (CNN) tienen la habilidad de detectar discontinuidades con una exactitud que supera el 90%, superando los métodos tradicionales (Köhler, 2021). El uso de inteligencia artificial en el análisis de soldaduras ha permitido un mejor reconocimiento de errores, reduciendo el tiempo de evaluación y potenciando la confiabilidad del procedimiento.

1.3.1. **MODELOS DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DEFECTOS EN SOLDADURAS**

Las Redes Neuronales Convolucionales (CNN) han demostrado ser altamente eficientes en el ámbito del mantenimiento industrial, gracias a su capacidad para examinar automáticamente patrones visuales sin intervención humana (LaBellerr, 2023). Su estructura, basada en capas convolucionales, facilita la identificación de texturas, bordes y patrones estructurales en imágenes, lo que las convierte en herramientas ideales para la detección de fallos y discontinuidades en componentes industriales, como las soldaduras. Esta habilidad de realizar diagnósticos rápidos y precisos en entornos industriales permite mejorar las estrategias de mantenimiento predictivo y preventivo, reduciendo el tiempo de inactividad y optimizando los recursos (Baldev, 2002).

VENTAJAS DEL USO DE CNN EN LA INSPECCIÓN DE SOLDADURAS:

- **Habilidad para ajustarse a imágenes de industria:** Las CNN poseen la habilidad de administrar imágenes de alta resolución tomadas en diferentes condiciones de luz y ángulos, asegurando una detección precisa y homogénea de defectos.

- **Formación para un aprendizaje integral:** Son capaces de adquirir automáticamente atributos pertinentes de las discontinuidades en soldaduras, lo que elimina la necesidad de diseñar manualmente un grupo de características concretas (Köhler, 2021).
- **Lista exacta de errores:** Con una exactitud que supera el 90%, identifican y distinguen fisuras, porosidades, socavaciones y otras irregularidades, disminuyendo la tasa de falsos positivos y negativos (Smith, 2018).
- **Escalabilidad y automatización:** Una vez entrenado, el modelo puede inspeccionar grandes volúmenes de imágenes en tiempo real, optimizando la eficiencia del proceso de inspección.

Aunque hay otros modelos de Inteligencia Artificial, como las Máquinas de Soporte Vectorial (SVM) y los Bosques Aleatorios, estos tienen sus propias restricciones. Ambos requieren una extracción manual de atributos antes de la clasificación, lo que provoca prejuicios y reduce la precisión en comparación con las CNN, que obtienen conocimientos directos de la información sin requerir intervención manual.

Metodologías como el aprendizaje no supervisado no son adecuadas para este tipo de reto, ya que el análisis de las soldaduras requiere una clasificación precisa basada en datos etiquetados.

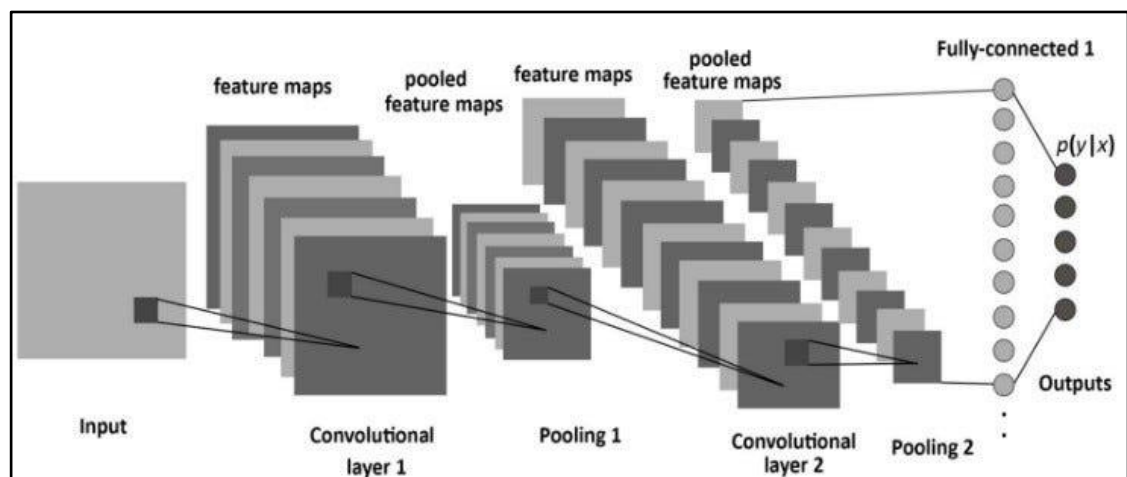


Ilustración 1-1 "Redes Neuronales Convolucionales (CNN)"

(Fuente: Data Universe)

1.3.2. APLICACIÓN DEL MODELO DE CONFUSIÓN EN LA EVALUACIÓN DEL SISTEMA

La matriz de confusión, que simboliza el modelo de confusión, se transforma en un instrumento esencial para valorar el rendimiento de los modelos de Inteligencia Artificial en labores de categorización.

Su papel crucial consiste en contrastar las proyecciones del modelo con los datos reales y ofrecer indicadores fundamentales que facilitan la comprensión de qué elementos del sistema están organizados y en qué se detectan fallos.

LAS MÉTRICAS EXTRAÍDAS DE LA MATRIZ DE CONFUSIÓN INCLUYEN:

- **Exactitud:** Representa la proporción de predicciones correctas en relación con el total de casos analizados.
- **Precisión:** Señala la cantidad de proyecciones acertadas en los casos categorizados como defectuosos, previniendo falsificaciones positivas.
- **Sensibilidad (o Proporción de Verdaderos Favorables):** Analiza la habilidad del modelo para identificar de manera adecuada todos los fallos que se encuentran en las imágenes.
- **Especificidad:** Calcula la cantidad de casos sin imperfecciones que fueron correctamente detectados, disminuyendo la posibilidad de falsos negativos.

Estas medidas facilitan un análisis más detallado del rendimiento del modelo, dado que no solo señalan su exactitud global, sino que también descubren patrones de error particulares. Esto es vital en la revisión de soldaduras, donde la malinterpretación entre fallos críticos y no críticos puede poner en riesgo la seguridad estructural de un componente.




Ilustración 1-2 "Matriz de Confusión"

(Fuente: Elaboración propia)

1.3.3. IMPORTANCIA DEL MODELO DE CONFUSIÓN EN EL PROYECTO

En este proyecto, el uso de la matriz de confusión es crucial (Labs, 2023), ya que permite un análisis detallado del desempeño de la CNN en la clasificación de discontinuidades en las soldaduras. (Optimization techniques in weld inspection, 2018), señalan que el análisis de matrices de confusión es vital para la mejora de modelos de inspección, ya que proporciona información vital acerca de falsos positivos y negativos, permitiendo cambios en la estructura del modelo para aumentar la precisión de clasificación. En este estudio, se utilizó la matriz de confusión para identificar patrones de error y alterar la estructura de la red neuronal, basándose en los hallazgos logrados.

- **Identificación de errores repetitivos:** Proporciona una clara identificación de qué tipos de discontinuidades exhiben más errores de clasificación y orientación para mejorar el modelo.
- **Mejora del procesamiento previo de imágenes:** Si se detectan fallos en algunas categorías, es posible modificar métodos de filtrado, contraste y segmentación con el fin de optimizar la calidad de las imágenes de entrada (Advances in AI and computer vision in industrial inspection, 2021).
- **Ajuste de hiper parámetros:** Basándonos en los descubrimientos de la matriz, podemos modificar aspectos como la cantidad de capas, el ritmo de aprendizaje y la función de activación, con el objetivo de mejorar la precisión del modelo.
- **Experimentado en entornos industriales:** La matriz de confusión asegura que el modelo no solo funcione correctamente en pruebas controladas, sino que también clasifique correctamente los defectos en circunstancias reales de inspección, acorde a normativas como (ASTM International E165/E165M, 2020) e (ISO 3452-1, 2023).

1.3.4. ESTRATEGIAS DE OPTIMIZACIÓN DEL DESEMPEÑO DEL MODELO DE IA

El modelo de confusión es esencial en el proceso de optimización de la Inteligencia Artificial, pues no solo mide el rendimiento global, sino que también facilita la mejora de la categorización de defectos a través de un estudio minucioso de los fallos.

- **Proceso de optimización iterativa:** Basándonos en los resultados de la matriz, podemos hacer cambios constantes en el modelo para mejorar su precisión.

- **Cambio del dataset:** Si existen errores en la clasificación de ciertos defectos, se pueden incluir más imágenes representativas en el conjunto de datos de entrenamiento.
- **Toma de decisiones basada en datos:** Permite realizar mejoras estratégicas en la arquitectura del modelo, técnicas de preprocesamiento y selección de características.

Como este proyecto tiene como objetivo adherirse a regulaciones internacionales como (ASTM International E165/E165M, 2020) y (ISO 3452-1, 2023), la implementación del modelo de confusión garantiza que la valoración del sistema sea imparcial y repetible en contextos industriales reales.

1.4. INSPECCIÓN CON LÍQUIDOS PENETRANTES EN ENSAYOS NO DESTRUCTIVOS (END)

Los líquidos penetrantes son uno de los métodos más frecuentemente empleados en los ensayos no destructivos (END) para identificar anomalías superficiales en materiales no porosos, como las soldaduras en estructuras de acero (ISO 3452-1, 2023). Su uso es esencial en el sector industrial gracias a su gran sensibilidad para identificar imperfecciones abiertas en la superficie, tales como fisuras, porosidades.

En contraste con métodos más sofisticados como la radiografía o los ultrasonidos, los líquidos penetrantes se emplean específicamente para detectar irregularidades en la superficie. Su aplicación es crucial en áreas como el cuidado industrial, donde es crucial identificar errores de manera oportuna para garantizar la integridad de las estructuras y la calidad de los materiales utilizados.

Las normas más relevantes son la (ASTM E165/E165M: Standard practice for liquid penetrant testing, 2020), (ISO 3452-1: Non-destructive testing – Penetrant testing – Part 1: General principles, 2023), que clasifica los estándares de calidad en las soldaduras de acero, níquel, titanio y sus aleaciones. Esta norma más reciente es esencial para establecer los criterios de aceptación o rechazo en las inspecciones industriales.

1.4.1. **ASTM E165/E165M: MÉTODOS Y PROCEDIMIENTOS**

La reglamentación ASTM E165/E165M define los métodos estándar para la evaluación con líquidos penetrantes, supervisando cada etapa del procedimiento, desde la preparación de la superficie hasta la documentación de los hallazgos (ASTM International E165/E165M, 2020). Su aplicación en áreas donde la calidad es crucial garantiza la repetibilidad del procedimiento.

El procedimiento comienza con la limpieza y acondicionamiento de la superficie, eliminando cualquier sobrante que pueda interferir con la infiltración del líquido y comprometer la precisión de la revisión. Después, se emplea el líquido penetrante, que puede ser fluorescente o visible, garantizando un tiempo de almacenamiento ideal para que el producto se introduzca en las imperfecciones superficiales. Tras este paso, se procede a la eliminación del exceso de penetrante, garantizando que solo quede retenido en las discontinuidades. Después, se utiliza el revelador, ya sea como polvo seco o en disolución líquida, con la finalidad de absorber el penetrante retenido y hacer perceptibles las señales de los defectos. Finalmente, se lleva a cabo el estudio visual e interpretación de los hallazgos, contrastando las señales identificadas con los estándares de aceptación establecidos en la legislación.

Adicionalmente, la ASTM E165/E165M categoriza los líquidos penetrantes en función de su método de eliminación, diferenciando entre los que se pueden lavar con agua, los que se pueden post-emulsificar y los que se pueden remover con solvente. Cada tipo de penetrante presenta beneficios particulares dependiendo del material examinado y las condiciones ambientales, lo que posibilita ajustar el procedimiento a diferentes contextos industriales.

1.4.2. ISO 3452: COMPATIBILIDAD Y SENSIBILIDAD DEL MÉTODO

La norma (ASTM International E165/E165M, 2020) se enriquece con la ISO 3452 al ofrecer pautas acerca de la compatibilidad de los líquidos penetrantes con diferentes materiales y condiciones del entorno. Una de sus aportaciones más significativas es la normativa que determina la luz mínima necesaria para las inspecciones, indicando que se necesita 1000 lux, dado que valores más elevados pueden incrementar la visibilidad y exactitud de la revisión.

Además, esta normativa mide la sensibilidad del método, garantizando que los penetrantes empleados puedan identificar discontinuidades mínimas en la superficie del material examinado. Por lo tanto, la norma ISO 3452 requiere ensayos de calidad en los productos utilizados, examinando aspectos como la viscosidad, estabilidad térmica.

1.4.3. TIPOS DE DISCONTINUIDADES DETECTABLES CON LÍQUIDOS PENETRANTES

Los líquidos penetrantes son extremadamente útiles para identificar irregularidades en la superficie durante una operación de soldadura. A continuación, se describen las categorías de discontinuidades más relevantes que pueden ser reconocidas:

- **Porosidades:** Los gases acumulados durante el proceso de endurecimiento de un material generan cavidades.




Ilustración 1-3 "Ensayo con Porosidad"

(Fuente: Elaboración propia)

- **Grietas:** Fisuras que pueden propagarse con el tiempo. Estas pueden originarse por tensiones térmicas, incompatibilidad de materiales.



Ilustración 1-4 "Ensayo con Grietas"

(Fuente: Elaboración propia)

- **Socavación:** Se presenta como un deterioro en las extremidades de la soldadura, lo que perjudica la unión. Este problema usualmente surge debido a una sobrecarga de corriente en la soldadura o a una distribución incorrecta del calor.




Ilustración 1-5 "Ensayo con Socavaciones"

(Fuente: Elaboración propia)

- **Inspección incompleta o defectuosa:** Errores en la aplicación. Factores como una mala aplicación del líquido penetrante, falta de capacitación del inspector pueden llevar a resultados imprecisos.



Ilustración 1- 6 "Ensayo Incompleto"

(Fuente: Elaboración propia)

1.4.4. VENTAJAS Y APLICACIONES DE LA INSPECCIÓN CON LÍQUIDOS PENETRANTES

En la industria, generalmente se utiliza el método de líquidos penetrantes por su alta sensibilidad para detectar discontinuidades en la superficie, su facilidad de administración y su menor costo en comparación con otros métodos de control. Se aplica en materiales no porosos como aceros, aluminios y polímeros, lo que permite identificar fisuras, porosidades y socavaciones que podrían comprometer la solidez estructural de un elemento.

Su aplicación sencilla permite su uso incluso en elementos con geometrías complejas, lo que le confiere una ventaja sobre otros métodos más limitados. No obstante, este procedimiento tiene algunas restricciones, dado que no facilita el reconocimiento de defectos internos, situación en la que tecnologías como la radiografía o los ultrasonidos son más adecuadas. No obstante, los líquidos penetrantes siguen siendo una herramienta crucial en los ensayos no destructivos (END), debido a su habilidad para identificar errores superficiales, su sencillez de uso y su menor costo en operación.

1.4.5. ESTANDARIZACIÓN Y GARANTÍA DE CALIDAD

En la inspección industrial, la utilización de líquidos penetrantes debe acatar las regulaciones internacionales que rigen los procedimientos de aplicación, garantizando consistencia, seguimiento y fiabilidad en los resultados. Entre las regulaciones más importantes se incluyen la ASTM E165/E165M e ISO 3452, las cuales definen los estándares para la preparación de la superficie, uso del penetrante, supresión del sobrante, uso del revelador y valoración de los resultados.

La documentación y trazabilidad de cada inspección es fundamental para garantizar la confiabilidad del proceso. Estas normativas establecen que todas las pruebas deben ser registradas y verificables, lo que permite auditorías y revisiones posteriores en industrias con altos requerimientos de seguridad, como la aeronáutica y la construcción.

Además, las regulaciones contemplan ensayos de calidad para los líquidos penetrantes, analizando su viscosidad, estabilidad térmica y contenidos de contaminantes para garantizar que no perjudiquen la integridad del material examinado. Además, establecen criterios para aceptar y rechazar discontinuidades, lo que facilita la categorización de defectos de forma objetiva y homogénea en diferentes áreas industriales.

La puesta en práctica correcta de estas normativas no solo garantiza la precisión y confiabilidad de las inspecciones, sino que también promueve la seguridad en las operaciones y la

prolongación de la durabilidad de los componentes revisados. En áreas donde la integridad estructural es esencial, el cumplimiento de estos estándares es esencial para prevenir fallos, reducir los peligros operacionales y garantizar la calidad de los productos.

1.5. PROCEDIMIENTOS PARA LA INSPECCIÓN DE SOLDADURAS CON LÍQUIDOS PENETRANTES

El estudio de soldaduras con líquidos penetrantes es un procedimiento de ensayo no destructivo (END) comúnmente empleado en el sector industrial para identificar anomalías en la superficie de materiales no porosos. La detección precoz de errores garantiza la calidad y la seguridad de la estructura.

Este procedimiento sigue cuidadosamente las directrices dictadas en reglamentos internacionales como la ASTM E165/E165M e ISO 3452, asegurando uniformidad, exactitud y monitoreo en los resultados.



DIAGRAMA 1-1 "Proceso de Inspección con Líquidos Penetrantes"

(Fuente: Elaboración Propia)

1.5.1. PREPARACIÓN DE LA SUPERFICIE PARA LA INSPECCIÓN

El primer paso en el estudio de líquidos penetrantes requiere la preparación de la superficie, dado que cualquier componente contaminante, como aceites, grasas, polvo o revestimientos, puede impedir la penetración del líquido y poner en peligro la sensibilidad del estudio.

Para garantizar una adecuada adhesión del penetrante, se emplean técnicas de limpieza especializadas, como el uso de disolventes, con la finalidad de asegurar que la superficie esté completamente libre de impurezas. Esta fase es vital para obtener conclusiones precisas, ya que la presencia de contaminantes podría poner en riesgo la fiabilidad del proceso y causar interpretaciones incorrectas.




Ilustración 1-7 "Limpiador SKC-S"

(Fuente: Elaboración propia)

1.5.2. APLICACIÓN DEL LÍQUIDO PENETRANTE EN LA SUPERFICIE DE INSPECCIÓN

Una vez que se ha preparado la superficie, se lleva a cabo la aplicación del líquido penetrante, que se distingue por su baja tensión superficial y elevada viscosidad, lo que facilita su infiltración en las mínimas discontinuidades existentes durante la soldadura.

El tiempo de permanencia del penetrante, también conocido como tiempo de difusión, es un indicador crucial que cambia dependiendo de la rugosidad de la superficie, la naturaleza del material y el tipo de penetrante empleado. Normativas como la ISO 3452-1 definen los tiempos

mínimos sugeridos para mejorar la identificación de discontinuidades, garantizando que el líquido tenga el tiempo necesario para infiltrarse en los defectos y simplificar su posterior detección.



Ilustración 1-8 "Probeta con penetrante"

(Fuente: Elaboración propia)

1.5.3. ELIMINACIÓN DEL EXCESO DE LÍQUIDO PENETRANTE

Tras el periodo de almacenamiento, es vital retirar de forma meticulosa el sobrante de penetrante de la superficie que se puede ver. La eliminación del sobrante se lleva a cabo a través de diversas técnicas, como el lavado con agua, el uso de disolventes o la aplicación de emulsificadores específicos, en función del tipo de penetrante que se emplee.

Este proceso es crucial, dado que una eliminación incorrecta puede producir señales equivocadas y comprometer la exactitud del análisis. Para prevenir esto, es crucial realizar la eliminación de manera meticulosa y regulada, garantizando que solo el penetrante retenido en las discontinuidades se mantenga en la superficie.



Ilustración 1-9 "Probeta limpia de exceso de penetrante"

(Fuente: Elaboración propia)

1.5.4. APLICACIÓN DEL REVELADOR

El siguiente procedimiento requiere el uso del revelador, un compuesto diseñado para atrapar el penetrante residual desde las discontinuidades y elevarlo a la superficie, produciendo señales perceptibles.

El revelador puede aparecer de varias formas, tales como polvo seco, suspensión húmeda o solución no acuosa, todas con características particulares que afectan la calidad y la claridad de las indicaciones.

Si se emplean penetrantes visibles, se requiere una iluminación blanca adecuada de 1000 lux para garantizar una interpretación exacta de los resultados.




Ilustración 1-10 "Resultado de ensayo"

(Fuente: Elaboración propia)

1.5.5. CONDICIONES DE ILUMINACIÓN Y SU IMPACTO EN LA INSPECCIÓN CON LÍQUIDOS PENETRANTES

Se aconseja una iluminación que exceda los 500 lux, preferentemente entre 800 y 1000 lux, con la finalidad de incrementar la visibilidad sin producir reflejos.

Es fundamental la iluminación para lograr la exactitud en la revisión con líquidos penetrantes. La norma (ISO 3452-1, 2023) dicta que la evaluación con penetrantes visibles debe llevarse a cabo con 1000 lux de luz blanca para asegurar una adecuada identificación de discontinuidades.

El uso de fuentes de luz adecuadas y ajustadas disminuye las equivocaciones en la revisión, asegurando resultados confiables y repetibles. Además, es vital llevar a cabo un control constante de la intensidad de luz para cumplir con las normativas y mantener la calidad de la evaluación.

TIPO DE INSPECCIÓN	ILUMINACIÓN REQUERIDA (según ISO 3452)
Penetrantes visibles	≥ 1000 lux (luz blanca)

Tabla 1-1 "Iluminación requerida según Norma ISO 3452-1"

(Fuente: Norma ISO 3452-1)

Además, es esencial realizar una comprobación regular de la intensidad de luz para garantizar que la iluminación se conserve dentro de los límites reglamentarios fijados por (ISO 3452-1, 2023), mejorando de esta manera la identificación de discontinuidades en la revisión con líquidos penetrantes.

1.5.6. CONSIDERACIONES AMBIENTALES

Las condiciones ambientales pueden afectar la eficacia del revelador, por lo que deben ser monitoreadas con cautela. Normativas como la (ASTM International E165/E165M, 2020) establecen intervalos recomendados para mejorar la inspección y garantizar los resultados.

- **Ambiente:** El líquido penetrante y el material examinado deben mantenerse en un intervalo de 10°C a 50°C, para prevenir cambios en la viscosidad del penetrante y garantizar su adecuada difusión en las discontinuidades.
- **Humedad:** En ambientes con alta humedad, el tiempo de secado del revelador puede prolongarse, afectando la formación y visibilidad de las indicaciones. Es aconsejable laborar en ambientes con humedad regulada para asegurar la estabilidad del procedimiento.

Es crucial supervisar estas variables para prevenir desvíos en los resultados y garantizar que el procedimiento de inspección sea exacto y repetible en diversas circunstancias operativas.

1.5.7. REGISTRO Y TRAZABILIDAD DE RESULTADOS DE LA INSPECCIÓN

El procedimiento de revisión con líquidos penetrantes necesita ser documentado correctamente para asegurar su seguimiento y el acatamiento de estándares internacionales, como la (ISO 3452-1, 2023). Por lo tanto, es esencial documentar cada fase del proceso, incluyendo los intervalos de aplicación y penetración del líquido, garantizando que se cumplan los parámetros fijados. Igualmente, la luz y la temperatura durante la revisión, dado que estos elementos afectan el ensayo. Además, es necesario incluir registros fotográficos y explicaciones minuciosas de las señales identificadas, lo que facilita la presencia de pruebas comprobables para auditorías y análisis de calidad futuros. Este método favorece la repetibilidad de los ensayos, simplificando la identificación de posibles desviaciones en los procedimientos y garantizando la observancia del cumplimiento.

1.6. NORMATIVAS INTERNACIONALES PARA LA INSPECCIÓN DE LÍQUIDOS PENETRANTES

Es fundamental poner en práctica las normativas internacionales en la evaluación de soldaduras mediante líquidos penetrantes para garantizar la fiabilidad del proceso. Estas normativas establecen procedimientos homogéneos que simplifican el logro de resultados en la identificación de discontinuidades superficiales. Además de regular los procesos de aplicación y evaluación, definen normas de aceptación que aseguran la calidad estructural de los componentes evaluados, disminuyendo de esta manera el riesgo de fallos en el sector industrial.

La implementación de regulaciones apropiadas no solo simplifica la comparación de los resultados obtenidos en diversos contextos, sino que también establece los cimientos para la incorporación de tecnologías en crecimiento, como la inteligencia artificial y la visión computacional, en la automatización de los ensayos no destructivos. Estas tecnologías pueden beneficiarse de la aplicación rigurosa de estándares internacionales, simplificando el entrenamiento de modelos de inteligencia artificial con datos estructurados y homogéneos, lo que aumenta la exactitud en la detección de fallos y reduce la subjetividad en la comprensión de los resultados.

En el ámbito industrial, algunas de las normativas más importantes para la inspección mediante líquidos penetrantes incluyen la ASTM E165/E165M, la ISO 3452 y la AWS D1.1, cada una con un enfoque específico. Mientras que las normas ASTM E165/E165M e ISO 3452 detallan los procedimientos de inspección, la AWS D1.1 se centra en los criterios de aceptación para soldaduras estructurales, funcionando como un complemento a las anteriores

1.6.1. APLICACIÓN DE LA NORMA ASTM E165/E165M EN LA INSPECCIÓN

La normativa ASTM E165/E165M se usa extensamente para la revisión con líquidos penetrantes en materiales no porosos. Su importancia radica en que establecen procedimientos para cada fase del ensayo, lo que permite una ejecución precisa del procedimiento. Desde la preparación de la superficie hasta el análisis de los resultados, estas normativas garantizan revisiones consistentes.

En sus directrices esenciales, enfatice la relevancia de limpiar adecuadamente la superficie antes de emplear el penetrante, ya que componentes contaminantes como aceites, pinturas o residuos pueden modificar la sensibilidad del ensayo. Además, defina las distintas clases de penetrantes, calculando en el tipo de material y las condiciones del entorno de inspección.

Esta normativa también rige el periodo de permanencia y revelación, que necesita un monitoreo riguroso para asegurar una absorción correcta del penetrante en las discontinuidades y una generación adecuada de indicaciones. La normativa también establece directrices para la interpretación de los resultados, proporcionando criterios para la evaluación y clasificación de las fallas detectadas, asegurando que los operadores puedan identificar discontinuidades con exactitud.

Teniendo en cuenta su cuidado minucioso en cada fase del procedimiento, la (AWS D1.1: Structural welding code – Steel, 2019) se utiliza extensamente en áreas donde la calidad y seguridad de las estructuras son fundamentales. Esta reglamentación define criterios concretos para la aceptación de discontinuidades en soldaduras estructurales, asegurando de esta manera un control de calidad estricto y normalizado.

1.6.2. REGULACIONES DE LA NORMA ISO 3452 EN LA INPECCIÓN DE SOLDADURAS

La ISO 3452 integra la ASTM E165/E165M, ofreciendo un marco normativo de uso mundial que asegura la compatibilidad y uniformidad en los procedimientos de inspección que emplean líquidos penetrantes. Su estrategia se centra en la armonización de estándares internacionales, lo que facilita su aplicación en proyectos industriales que necesitan acatar regulaciones de aceptación mundial.

Uno de los aspectos más destacados de esta regulación es su énfasis en la luz y las condiciones del entorno durante el proceso de evaluación. Se determina que es esencial realizar evaluaciones visuales bajo luz blanca con un nivel sugerido de 1000 lux, lo que incrementa la visibilidad y la exactitud en la identificación de discontinuidades.

Esta exigencia es esencial para garantizar una adecuada comprensión de las señales superficiales y minimizar posibles fallos interpretativos causados por una iluminación insuficiente. Asimismo, la ISO 3452 establece normas de temperatura para preservar la estabilidad del proceso. Los líquidos penetrantes pueden experimentar cambios en su viscosidad y capacidad de difusión si la temperatura varía significativamente, lo que podría afectar la precisión de la inspección. Para evitar inconsistencias en los resultados, la norma establece un rango de temperatura óptimo que debe respetarse durante todo el procedimiento.

La norma ISO 3452 también establece la remoción del sobrante de penetrante, garantizando que únicamente el líquido acumulado en las discontinuidades se mantenga en la superficie antes de utilizar el revelado. La ley define varios procedimientos para realizar esta eliminación, con la finalidad de prevenir la presencia de falsos positivos o negativos en la identificación de defectos.

La ISO 3452, debido a su enfoque integral y su alineación con otras regulaciones de inspección, es ampliamente utilizada en campos donde se requiere uniformidad en los ensayos a nivel mundial. Su puesta en marcha es crucial en empresas con certificaciones internacionales y en proyectos que exigen altos estándares de calidad.

1.6.3. COMPARACIÓN DE NORMAS: ISO 3452 VS. ASTM E165

CRITERIO	ISO 3452	ASTM E165
OBJETIVO	Proporcionar los principios generales para la inspección mediante líquidos penetrantes.	Establecer procedimientos para pruebas no destructivas utilizando líquidos penetrantes
ALCANCE	Aplicable a metales ferrosos, no ferrosos, cerámicas densas y ciertos plásticos no porosos.	Dirigido a materiales metálicos no porosos, vidrio y algunos plásticos densos
SENSIBILIDAD	Clasificación en 5 niveles para fluorescentes según la capacidad de detección de discontinuidades: Nivel 1 (baja) a Nivel 5 (ultra alta). Sensibilidad evaluada en términos de tamaño mínimo detectable de discontinuidad (~0.1 mm para Nivel 5).	Clasificación similar: Sensibilidad definida por pruebas comparativas en piezas estándar como ASTM E1209. Nivel más alto (Tipo I Nivel 4) detecta discontinuidades de hasta ~0.1 mm.
DISCONTINUIDADES DETECTABLES	Grietas , porosidades, laminaciones, socavaciones, falta de fusión, solapes y contracciones superficiales.	Grietas , uniones mal soldadas, pliegues fríos, contracciones superficiales, laminaciones y fugas visibles.
REQUISITOS DE ILUMINACIÓN	Penetrantes fluorescentes: mínimo 1,000 $\mu\text{W}/\text{cm}^2$ de radiación UV-A; penetrantes visibles: 1000 lux.	Requiere condiciones similares: $\geq 1,000 \mu\text{W}/\text{cm}^2$ para fluorescentes

Tabla 1-2 "Comparación de normas: ISO 3452 vs ASTM E165

(Fuente: Norma ISO 3452-1 y ASTM E165)

1.6.4. CONSIDERACIONES DE LA NORMA AWS D1.1 EN LA INSPECCIÓN DE SOLDADURAS

En este estudio, se ha elegido la norma AWS D1.1 debido a su relevancia en el estudio de las soldaduras estructurales de acero. La robustez de la estructura se basa en la calidad de las uniones soldadas, por lo que es esencial cumplir con normativas estrictas para asegurar la seguridad y resistencia de los componentes evaluados.

Esta normativa establece normas técnicas específicas para analizar las soldaduras a través de exámenes no perjudiciales, tales como líquidos penetrantes, ultrasonido y radiografía, con el objetivo de detectar discontinuidades que podrían perjudicar el rendimiento estructural. Dentro de los defectos regulados se encuentran fisuras, porosidades, ausencia de fusión y socavaciones, dado que estas anomalías son causadas por dichas imperfecciones.

A diferencia de las normativas ASTM E165/E165M e ISO 3452, que se centran en el método de inspección con líquidos penetrantes, la AWS D1.1 define los criterios de aceptación y las clases de errores que requieren análisis en soldaduras estructurales. Esta regulación no especifica los procedimientos específicos para la revisión con líquidos penetrantes, sino que establece qué tipos de discontinuidades son aceptables.

Desde este punto de vista, la AWS D1.1 requiere ser complementada con normativas más exactas sobre exámenes no destructivos, como la (ASTM International E165/E165M, 2020) y la (ISO 3452-1, 2023), que proporcionan pautas acerca de la preparación de la superficie, aplicación del líquido penetrante, eliminación del sobrante, empleo del revelador e interpretación. La inclusión de estos criterios garantiza que el proceso de inspección sea completo.

1.6.5. ALCANCE Y APLICABILIDAD DE LAS NORMAS EN INSPECCIÓN DE SOLDADURAS

La reglamentación AWS D1.1 comprende las exigencias técnicas y de seguridad para la soldadura en estructuras de acero, supervisando desde la preparación y realización de la soldadura hasta su revisión, aprobación y conservación. Su meta principal es garantizar que todas las uniones soldadas satisfagan los criterios de calidad e integridad estructural requeridos en el sector industrial, minimizando la posibilidad de averías mecánicas y asegurando la resistencia de las soldaduras bajo diversas cargas y condiciones de operación.

La normativa abarca una extensa gama de usos, que van desde soldaduras en aceros al carbono y aceros de baja aleación, hasta procedimientos particulares para estructuras expuestas a esfuerzos dinámicos y cargas de gran peso. En este escenario, el AWS D1.1 administra elementos como:

- **Preparación y limpieza de superficies:** Establece procedimientos para la eliminación de contaminantes como óxidos, aceites, humedad y otros residuos que puedan afectar la calidad de la soldadura.
- **Selección de materiales de aporte:** Define qué materiales y consumibles de soldadura deben utilizarse en función del tipo de acero y la aplicación específica.
- **Control de las temperaturas antes y después de la soldadura:** Observar el intervalo de temperatura apropiado para minimizar la existencia de tensiones internas y evitar anomalías como fisuras en el área que ha sido impactada por el calor.

Además, la normativa establece disposiciones concretas para uniones soldadas, tomando en cuenta tanto miembros tubulares como no tubulares, garantizando que las uniones soldadas sean capaces de resistir esfuerzos mecánicos, cansancio y vibraciones sin afectar la estructura en la que se ubican.

La legislación exige certificaciones obligatorias para los soldadores, garantizando que posean las habilidades requeridas para llevar a cabo el trabajo sin fallos, en el que las fluctuaciones en el método de soldadura pueden provocar irregularidades en la calidad de las uniones.

Respecto a la revisión, la AWS D1.1 valora la utilización de pruebas no perjudiciales, como líquidos penetrantes, para identificar anomalías superficiales en las soldaduras. Adicionalmente, establece criterios de aceptación exhaustivos, además de ofrecer pautas para la reparación de soldaduras, garantizando que todas las fases del proceso de inspección se ajusten a los estándares requeridos.

1.6.6. CRITERIOS DE ACEPTACIÓN DE DEFECTOS SEGÚN NORMAS INTERNACIONALES

La AWS D1.1 establece criterios de aceptación y rechazo concretos para las irregularidades detectadas en las soldaduras estructurales, asegurando evaluaciones, normalizadas y en consonancia con las regulaciones internacionales. Estos parámetros ayudan establecer si una soldadura satisface los estándares de calidad

Uno de los componentes fundamentales de esta normativa es su énfasis en la rastreabilidad y documentación del procedimiento de soldadura, garantizando que cada soldadura verificada disponga de informes de evaluación, resultados de la revisión. Esta capacidad de supervisar simplifica auditorías.

**CAPÍTULO 2: DISEÑO Y DESARROLLO DEL MODELO DE
INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN
DE DISCONTINUIDADES EN SOLDADURAS**

2.1. ESTRATEGIA TECNOLÓGICA PARA LA INSPECCIÓN AUTOMATIZADA DE SOLDADURAS

Los avances en la automatización, la inteligencia artificial (IA) y la visión computacional han impulsado cambios significativos en los procesos industriales, proporcionando una mayor exactitud y uniformidad en las revisiones. No obstante, para potenciar su rendimiento, resulta crucial integrar diversas tecnologías que potencian sus capacidades y reducen sus limitaciones.

En este estudio se ha desarrollado un modelo que utiliza redes neuronales convolucionales (CNN), lo que permite una revisión en diferentes situaciones operativas. Este procedimiento no solo mejora la detección de irregularidades, sino que también incrementa la rastreabilidad y la normalización del procedimiento.

La sección subsiguiente detalla las tecnologías utilizadas, especificando su papel en la identificación de errores y su contribución a la optimización de la revisión de soldaduras.

2.2. DISEÑO E IMPLEMENTACIÓN DEL MODELO DE INTELIGENCIA ARTIFICIAL PARA LA INSPECCIÓN DE SOLDADURAS

Para garantizar la detección automatizada de irregularidades en las soldaduras, el sistema integra diversas herramientas tecnológicas que trabajan en conjunto para aumentar la precisión y confiabilidad del proceso. En esta sección se detallan las tecnologías esenciales del modelo de inspección, especificando su función específica dentro del sistema y su función en la identificación de errores.

2.2.1. APLICACIÓN DE VISIÓN COMPUTACIONAL EN LA INSPECCIÓN DE SOLDADURAS

El sistema de inspección automatizado se basa en la visión computacional, lo que simplifica la recolección, el tratamiento y el examen de imágenes de soldaduras sin requerir la participación humana (Sección 1.2.2). El modelo posee la capacidad para reconocer patrones visuales relacionados con errores en las soldaduras y clasificarlos según su imperfección.

El sistema distingue entre diferentes tipos de soldaduras según su estado. Primero, seleccione las que están en condiciones ideales, es decir, las que no muestran imperfecciones relevantes. En cambio, identifique las soldaduras no finalizadas, las cuales indican errores en la fusión del material. Además, posee la capacidad de identificar la presencia de fisuras, las cuales podrían amenazar la resistencia estructural de la unión. Igualmente, identifique porosidades y zonas

generadas por el almacenamiento de gases durante el proceso de solidificación del metal fundido. Finalmente, detecte socavaciones, que son disminuciones en los bordes de la soldadura que influyen en la conexión del metal.

Para garantizar la calidad de los datos analizados y mejorar la detección de discontinuidades, el sistema utiliza técnicas de preprocesamiento de imágenes que disminuyen la variabilidad de los resultados. Entre estos procedimientos se encuentra la normalización de píxeles, que altera los niveles de intensidad con el objetivo de aumentar el contraste y tornar los defectos más visibles. Además, se aplica la corrección del brillo, que equilibra las fluctuaciones en la luz para prevenir cambios en la detección. Además, el modelo utiliza un procedimiento de redimensionarían de imágenes para normalizar sus dimensiones y garantizar la uniformidad en el manejo de los datos.

2.2.2. ARQUITECTURA DEL MODELO BASADO EN REDES NEURONALES CONVOLUCIONALES (CNN)

El modelo creado utiliza las Redes Neuronales Convolucionales (CNN), un modelo de inteligencia artificial reconocido por su habilidad para examinar imágenes y categorizar patrones complejos (Sección 1.3.1). Estas redes se han aplicado en varias aplicaciones industriales, especialmente en la revisión de soldaduras, donde se ha comprobado que su exactitud y eficacia sobrepasan los procedimientos convencionales (Köhler, 2021).

Desarrollo del Modelo CNN

El modelo está formado por diversas capas, cada una cumpliendo un rol particular en el procesamiento de imágenes:

- **Capas convolucionales (Conv2D):** Capturan aspectos esenciales de las imágenes mediante filtros particulares, lo que simplifica la detección de patrones singulares en la superficie de la soldadura.
- **Capas de MaxPooling:** Reducen la dimensionalidad de los datos, manteniendo la información más relevante y optimizando la eficiencia computacional sin perder precisión en la detección.
- **Capas densas (Fully Connected Layers):** Procesan la información extraída y generan la clasificación final de la imagen, determinando el tipo de discontinuidad presente en la soldadura.

Optimización del Modelo

Para mejorar la precisión del sistema y evitar obstáculos como el sobreajuste, se han implementado diversas tácticas de optimización que refuerzan la capacidad de ampliar el modelo:

- **Dropout:** Durante el entrenamiento, desactiva de forma aleatoria algunas neuronas, lo que evita que el modelo se focalice excesivamente en patrones específicos y mejora su resistencia frente a variaciones en la información.
- **Data Augmentation:** Aplica transformaciones artificiales a las imágenes de entrenamiento, como rotaciones, reflejos y ajustes de brillo. Esto permite ampliar la diversidad del conjunto de datos y mejorar el rendimiento del modelo ante diferentes condiciones de inspección.

2.2.3. SELECCIÓN Y CONFIGURACIÓN DE SENSORES Y EQUIPOS DE CAMARA

Para asegurar la exactitud del modelo revisado, el sistema utiliza cámaras de alta resolución y sensores de luz particulares. Estos aparatos garantizan la captura de imágenes de alta calidad, esenciales tanto para la capacitación como para el estudio del modelo de inteligencia artificial.

Las exigencias técnicas de los equipos comprenden:

- **Resolución idónea mínima:** Fomenta un reconocimiento exacto de los pormenores de las discontinuidades en las soldaduras, garantizando que las averías sean reconocibles.
- **Iluminación de 1000 lux (según la norma ISO 3452):** Se ajusta a los estándares definidos para la revisión con líquidos penetrantes, optimizando la identificación de imperfecciones en diversas condiciones de luz.
- **Calibración constante:** Garantiza la homogeneidad en la recopilación de datos, evitando variaciones en la calidad de las imágenes y asegurando los resultados durante el procedimiento de revisión.

2.3. DISEÑO DEL MODELO Y CONFIGURACIÓN DEL MODELO DE INTELIGENCIA ARTIFICIAL

El modelo de inteligencia artificial (IA) creado para identificar anomalías en las soldaduras se fundamenta en una estructura denominada Red Neuronal Convolutiva (CNN), ideada para el procesamiento y análisis de imágenes de alta exactitud. Su diseño se centra en asegurar una categorización eficaz de los defectos a través de los métodos de aprendizaje profundo que seleccionen.

Para cumplir con esta meta, se definen tácticas para mejorar el flujo de datos, preprocesar imágenes y generar un ambiente de desarrollo escalable en la nube.

A continuación, se exponen los componentes fundamentales del modelo:

2.3.1. ARQUITECTURA DEL MODELO DE IA

El modelo se fundamenta en una Red Neuronal Convolutiva (CNN), creada para identificar rasgos visuales de soldaduras y categorizar imágenes en diversas clases de discontinuidades.

CÓDIGO DE IMPLEMENTACIÓN DEL MODELO CNN

```
import torch
import torch.nn as nn
model = nn.Sequential(
    nn.Conv2d(3, 32, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(32, 64, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(64, 128, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Flatten(),
    nn.Linear(outputSize, 128), # Capa totalmente conectada ajustada
    nn.ReLU(),
    nn.Linear(128, numClasses) # Capa de salida
)
```

Código 2-1 "Red Neuronal CNN en Pytorch"

(Fuente: Elaboración propia – Colab Google)

Este modelo facilita el manejo de imágenes y consigue una categorización exacta de las discontinuidades en los procesos de soldadura.

2.3.2. FLUJO DE DATOS EN EL SISTEMA Y PROCESAMIENTO EN EL SISTEMA

Para construir el modelo de inteligencia artificial es necesaria una correcta organización y preprocesamiento de la información. Así pues, las imágenes empleadas se segmentan en tres subgrupos esenciales, garantizando un entrenamiento equilibrado y una valoración del rendimiento del modelo.

- **Train (Entrenamiento):** Incorpora 72 imágenes por categoría y se utiliza para ajustar los parámetros del modelo, lo que permite el aprendizaje de patrones relevantes de discontinuidades en las soldaduras.
- **Val (Validación):** Incluye 8 imágenes por categoría y se emplea para calibrar los hiperparámetros, evitando problemas como el sobreajuste y garantizando una ampliación del modelo.
- **Test (Prueba):** Incluye 20 imágenes por clasificación con el propósito de evaluar el rendimiento final del modelo en datos nuevos, asegurando su eficacia antes de su implementación en entornos industriales.

PREPROCESAMIENTO Y CARGA DE DATOS

Previo a ser incluido en el modelo, las imágenes pasan por una serie de modificaciones para estandarizar y mejorar su procesamiento. Dentro de estas alteraciones se incluyen:

- **Redimensionamiento:** Cada imagen tenga una resolución de 500x500 píxeles para preservar la uniformidad en la base de datos.
- **Conversión a tensor:** Transformar un tensor en una organización PyTorch. Esto facilita su procesamiento eficaz en el ambiente de aprendizaje profundo.
- **Normalización:** Los valores de los píxeles se normalizan en un rango de 0.5, lo que mejora la estabilidad del entrenamiento y fomenta que la red neuronal converja de manera más rápida durante el proceso de ajuste de peso.

Esta estructura de datos, junto con las tácticas de preprocesamiento, garantiza que el modelo funcione con datos limpios y estandarizados, lo que facilita la detección de discontinuidades en soldaduras con alta precisión.

CÓDIGO DE PREPROCESAMIENTO Y CARGA DE DATOS

```

transform = transforms.Compose([
    transforms.Resize((sizeVar, sizeVar)),
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5]) #
Normalización
])

# Cargar los datos
def load_data(directory):
    dataset = datasets.ImageFolder(directory, transform=transform)
    dataloader = DataLoader(dataset, batch_size=batchSize, shuffle=True)
    return dataloader

trainData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenet
rantes/Dataset/AugmentedImages')
validationData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenet
rantes/Dataset/Images2')

```

Código 2-2 "Preprocesamiento y Carga de Datos"

(Fuente: Elaboración propia – Colab Google)

"transforms.Compose(): Este tipo de PyTorch se emplea para implementar transformaciones en las imágenes, tales como redimensionar, normalizar y efectuar incrementos de datos (como rotaciones, volteos y desplazamientos). Estas alteraciones aseguran que los datos estén en un formato uniforme y listo para la creación del modelo."

"DataLoader(): Este comando captura las imágenes del archivo específico utilizando las transformaciones establecidas anteriormente. Además, organiza los datos en lotes (batch_size) y permite un acceso eficiente a la información durante el entrenamiento y la comprobación."

2.3.3. IMPLEMENTACIÓN DE GOOGLE COLAB Y GOOGLE DRIVE

Google Colab se utiliza en la creación y capacitación del modelo de inteligencia artificial, una plataforma de computación en la nube que ofrece acceso a unidades de procesamiento gráfico (GPU) y tensorial (TPU). Esto permite una notable aceleración de los cálculos vinculados al aprendizaje profundo, optimizando el tiempo y los recursos necesarios para la elaboración del modelo.

VENTAJAS DE GOOGLE COLAB

El uso de esta plataforma brinda múltiples beneficios en el avance del modelo, destacando entre ellos:

- **Acceso a recursos computacionales avanzados:** Promueve el uso libre de GPU y TPU, mejorando el rendimiento de la formación y reduciendo el tiempo de procesamiento en comparación con una CPU tradicional.
- **Almacenamiento en la nube con Google Drive:** Promueve la administración, estructuración y acceso a los conjuntos de datos sin ocupar espacio en el equipo local. Esto facilita la administración de grandes cantidades de imágenes sin limitaciones en el almacenamiento.
- **Colaboración en tiempo real:** Facilita la distribución y modificación eficaz del código desde cualquier aparato, simplificando el trabajo colaborativo y la revisión de los experimentos en marcha.

MONTAJE DE GOOGLE DRIVE EN GOOGLE COLAB

Para tener acceso a las bases de datos guardadas en Google Drive y emplearlas en el modelo, se requiere configurar el almacenamiento en la nube dentro de Google Colab. Se consigue esto al ejecutar el código siguiente en una celda de la plataforma:

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

Código 2-3 "Entorno Google Drive en Colab Google"

(Fuente: Elaboración propia – Colab Google)

Este método facilita la unión entre Google Drive y Colab, garantizando que los archivos del conjunto de datos puedan ser empleados directamente en el ambiente de entrenamiento. Esta implementación mejora el flujo de trabajo y asegura la disponibilidad de los datos en cualquier instante y desde cualquier aparato.

2.4. PROCESO DE ENTRENAMIENTO Y VALIDACIÓN DEL MODELO

El progreso del modelo de inteligencia artificial centrado en la evaluación de discontinuidades en los procedimientos de soldadura se lleva a cabo a través de una serie de fases estructuradas. Desde la recolección de datos hasta la evaluación definitiva del rendimiento, cada etapa es crucial para garantizar que el modelo sea preciso y robusto en la detección de errores.

A partir de ahora, se detalla cada etapa de la implementación, que abarca desde la carga y el preprocesamiento de las imágenes, hasta la configuración del modelo, la capacitación y la valoración de su rendimiento.

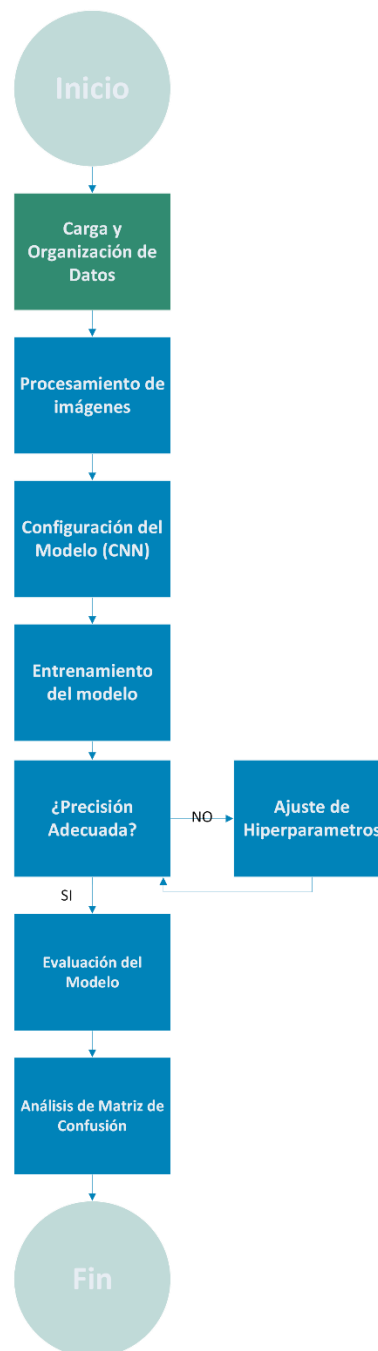


DIAGRAMA 2-1 “Proceso de Entrenamiento y Validación”

(Fuente: Elaboración propia)

2.4.1. ETAPAS DEL ENTRENAMIENTO DEL MODELO DE IA

Para realizar el entrenamiento del modelo, se realiza una serie de etapas organizadas, que van desde la carga y preprocesamiento de las imágenes hasta la validación y prueba del modelo en información nueva.

CARGA DE DATOS

El conjunto de datos se almacena en Google Drive y se ha explicado previamente en la sección 2.3.3 cómo acceder dentro del entorno de ejecución de Google Colab.

ORGANIZACIÓN DEL DATASET

Las imágenes se agrupan en tres categorías fundamentales: entrenamiento (Train), validación (Val) y prueba (Test). Para obtener más información acerca del volumen de datos y su distribución, consulte la sección 2.3.2

PREPROCESAMIENTO DE IMÁGENES

Antes de crear el modelo, resulta crucial llevar a cabo un proceso de preprocesamiento para incrementar su calidad y garantizar su uniformidad. Estas alteraciones no solo aumentan la precisión del modelo, sino que también reducen la posibilidad de sobreajuste, propiciando el desarrollo de la red neuronal.

PARA LOGRAR ESTA META, SE REALIZAN LOS PASOS ESENCIALES SIGUIENTES:

- **Reglamentación de los píxeles:** Las intensidades se adecuan en el intervalo de -0.5 a 0.5, lo cual estabiliza la formación y acelera la convergencia del modelo.
- **Conversión:** Todas las imágenes cumplen con un tamaño estándar de 500x500 píxeles, asegurando uniformidad en la introducción de datos y facilitando su procesamiento a través de la red neuronal.
- **Modificación del brillo y contraste:** Se mejoran los niveles de luz y contraste para destacar las discontinuidades en la soldadura, lo que mejora su identificación por el modelo.
- **Ajuste a un formato tensor:** Las fotografías se transforman en tensores de PyTorch, un formato adecuado para el manejo de redes neuronales, lo que permite su aplicación eficiente en el entrenamiento.

Este conjunto de transformaciones garantiza que el modelo funcione con datos homogéneos, mejorando su capacidad de aprendizaje y reduciendo la posibilidad de errores en la clasificación de discontinuidades.

PREPARACION DEL DATA SET: TRANSFORMACIONES

```
# Transformaciones para las imágenes
transform = transforms.Compose([
    transforms.Resize((sizeVar, sizeVar)),
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5]) #
Normalización
])

# Cargar los datos
def load_data(directory):
    dataset = datasets.ImageFolder(directory, transform=transform)
    dataloader = DataLoader(dataset, batch_size=batchSize, shuffle=True)
    return dataloader

trainData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenetrantes/Dataset/AugmentedImages')
validationData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenetrantes/Dataset/Images2')
```

Código 2-4 "Preparación del Dataset: Transformaciones y DataLoader"

(Fuente: Elaboración propia – Colab Google)

2.4.2. CONDICIONES Y PROCESAMIENTO DE IMÁGENES

El modelo de inteligencia artificial ha sido diseñado para clasificar imágenes en cinco categorías de discontinuidades en soldaduras:

- **Buen Estado (TIPO 1):** Superficie sin defectos.
- **No Terminado (TIPO 2):** Ensayo incompleto
- **Agrietamiento (TIPO 3):** Presencia de fisuras que pueden comprometer la estructura.
- **Porosidad (TIPO 4):** Cavidades causadas por gases atrapados en la solidificación.
- **Socavación (TIPO 5):** Depresiones en los bordes de la soldadura, debilitando la unión.

Para asegurar un entrenamiento eficiente, se han definido los siguientes parámetros clave del modelo:

PARÁMETROS DE MODELO E IMÁGENES

```
• sizeVar = 150
• batchSize = 32
• numClasses = 5
• epochs = 100
• inputSize = 150
```

Código 2-5 "Parámetros de Imágenes Visión Computacional"

(Fuente: Elaboración propia – Colab Google)

AUMENTACIÓN DE DATOS

Se emplean técnicas de ampliación de datos para evitar que el modelo recuerde imágenes específicas y potenciar su capacidad para generalizar. Estas estrategias generan imágenes más similares a las primeras, simulando diversas condiciones ambientales y variaciones en la ubicación. Entre las transformaciones aplicadas se incluyen:

- **Rotaciones en distintas direcciones:** Con el objetivo de aumentar la variedad, se efectúan giros de 15° y 30° en ambos sentidos.
- **Espejo horizontal y vertical:** Las imágenes son rotadas para generar diferentes puntos de vista.
- **Escalado:** Se exhiben imágenes de diferentes tamaños, reduciendo su tamaño al 80% y 90% de la versión original.
- **Ajustes de iluminación:** Se ajustan y contrastan los niveles de luz para replicar las variaciones en la iluminación del ambiente.

Estas modificaciones permiten el desarrollo de múltiples versiones de una misma imagen, fortaleciendo el conjunto de datos y potenciando la capacidad para generalizar el modelo.

ROTACIONES Y ESCALADO EN IMÁGENES

```

Genera 8 variantes de la imagen original aplicando transformaciones.
"""
image = Image.open(image_path)
variants = []

# Variantes
variants.append(image.rotate(15)) # Rotación de 15° derecha
variants.append(image.rotate(-15)) # Rotación de 15° izquierda
variants.append(ImageOps.mirror(image)) # Espejo horizontal
variants.append(image.transpose(Image.FLIP_TOP_BOTTOM)) # Espejo
vertical
variants.append(image.rotate(30)) # Rotación de 30° derecha
variants.append(image.rotate(-30)) # Rotación de 30° izquierda
variants.append(image.resize((int(image.width * 0.8), int(image.height
* 0.8)))) # Escalado 80%
variants.append(image.resize((int(image.width * 0.9), int(image.height
* 0.9)))) # Escalado 90%

```

Código 2-6 "Aumento de Datos: Rotaciones, Espejos y Escalado en Imágenes"

(Fuente: Elaboración propia – Colab Google)

2.4.3. ESTRATEGIAS DE ENTRENAMIENTO Y AJUSTE DEL MODELO

Las Redes Neuronales Convolucionales (CNN) constituyen la base del modelo de inteligencia artificial, cuyo diseño y funcionamiento se describen en la sección 2.2.2

Como se indicó previamente, esta estructura permite el procesamiento de imágenes de soldaduras en Múltiples capas, adquiriendo información vital y clasificando de manera precisa las discontinuidades. A continuación, se resumen los niveles esenciales del modelo:

- **Capas convolucionales:** Extraen características visuales fundamentales como bordes, texturas y patrones distintivos en las soldaduras.
- **Capas de MaxPooling:** Reducen la cantidad de información procesada sin perder detalles importantes, optimizando el uso de recursos computacionales.
- **Capas densas:** Procesan la información extraída y permiten la clasificación de las imágenes en una de las cinco categorías de discontinuidades.
- **Función Softmax:** Asigna una probabilidad a cada clase, determinando la categoría final de la imagen analizada.

Para optimizar el rendimiento del modelo y mejorar su capacidad de generalización, se implementan diversas estrategias de entrenamiento, las cuales se detallan a continuación.

CAPAS DEL MODELO AJUSTADA

```
# Ajustar el modelo con la capa totalmente conectada correcta
model = nn.Sequential(
    nn.Conv2d(3, 32, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(32, 64, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(64, 128, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Flatten(),
    nn.Linear(outputSize, 128), # Capa totalmente conectada ajustada
    nn.ReLU(),
    nn.Linear(128, numClasses) # Capa de salida
```

Código 2-7 "Implementación de Red Neuronal Convolutiva con Capa Totalmente Conectada Ajustada"

(Fuente: Elaboración propia – Colab Google)

PROCESO DE ENTRENAMIENTO

En el entrenamiento, el modelo de Red Neuronal Convolutiva (CNN) toma fotografías de soldaduras y, a través de su cálculo, realiza una predicción de clase, o sea, determina qué clase de discontinuidad coincide con la imagen.

Esta proyección se distingue del etiquetado inicial de la imagen, examinando la discrepancia entre ambas a través de una función de pérdida (como Loss de Cross-Entropy).

RETROPROPAGACIÓN DEL ERROR Y AJUSTE DE PESOS

Para mejorar la precisión del modelo, se utiliza un proceso llamado retropropagación del error (Backpropagation). Este mecanismo ajusta los pesos de la red neuronal en cada iteración para reducir el error en futuras predicciones.

El proceso se realiza en las siguientes etapas:

1. **Cálculo del error:** Se analiza la discrepancia entre la representación del modelo y la etiqueta original.
2. **Cálculo del gradiente:** Se determina el ajuste de los pesos con el objetivo de minimizar al mínimo el error.
3. **Ajuste de pesos:** Se utilizan algoritmos de optimización, como Adam o SGD (Descenso Gradiente Stochastic), con el objetivo de rejuvenecer los pesos de la red y mejorar su desempeño.

ITERACIONES DEL ENTRENAMIENTO

El entrenamiento se realiza durante 100 periodos de tiempo. En cada época, el esquema:

- Adquiere conocimientos de patrones en las imágenes de práctica.
- Verifique su rendimiento en el conjunto de validación para prevenir un sobreajuste.
- Modifica sus pesos para incrementar la exactitud en etapas futuras.

Si tras múltiples iteraciones, la función de pérdida deja de reducirse considerablemente, se considera que el modelo ha convergido, o sea, ha adquirido conocimientos de forma óptima.

RESULTADO DEL ENTRENAMIENTO

Una vez finalizado este proceso, el modelo estará listo para analizar imágenes recientes y detectar con precisión discontinuidades en soldaduras. Se evaluará la efectividad del modelo a través de indicadores como la Precisión (Accuracy), el Recall y el F1-Score, que simplificarán la comprobación de su capacidad para clasificar antes de su implementación final.

ENTRENAMIENTO DE MODELO IA

```
# Configurar el optimizador y la pérdida
optimizer = optim.Adam(model.parameters(), lr=0.001)
criterion = nn.CrossEntropyLoss()

# Entrenamiento
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
model.to(device)

for epoch in range(epochs):
    model.train()
    runningLoss = 0.0
    for inputs, labels in trainData:
        inputs, labels = inputs.to(device), labels.to(device)
        optimizer.zero_grad()
        outputs = model(inputs)
        loss = criterion(outputs, labels)
        loss.backward()
        optimizer.step()
        runningLoss += loss.item()

    print(f"Epoch {epoch + 1}/{epochs}, Loss: {runningLoss /
len(trainData)}")
```

Código 2-8 "Entrenamiento de Modelo de IA con CUDA y PyTorch para Visión Computacional"

(Fuente: Elaboración propia – Colab Google)

2.4.4. EVALUACIÓN DEL DESEMPEÑO MEDIANTE MÉTRICAS DE RENDIMIENTO

Es vital valorar el rendimiento del modelo para identificar discontinuidades en las soldaduras. Para lograrlo, se utiliza un conjunto de validación autónoma, que posibilita evaluar cuánto se ha extendido el modelo a nuevas imágenes que no ha observado durante el entrenamiento.

El desempeño se evalúa a través de varias métricas que ofrecen una perspectiva exhaustiva de su eficacia y potenciales áreas de mejora.

MÉTRICAS DE EVALUACIÓN

El modelo es evaluado con tres métricas clave en clasificación de imágenes:

Precisión (Accuracy): Indica el porcentaje de imágenes que fueron clasificadas correctamente en sus respectivas categorías. Se calcula como:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{Fórmula 2.1}$$

Donde:

- TP (True Positives): Casos correctamente clasificados como defectos.
- TN (True Negatives): Casos correctamente clasificados como "Buen Estado".
- FP (False Positives): Imágenes sin defectos clasificadas erróneamente como defectuosas.
- FN (False Negatives): Imágenes con defectos que no fueron detectadas correctamente.

Recall (Sensibilidad): Evalúa qué tan bien el modelo detecta los defectos reales en la soldadura. Un valor bajo de recall indica que el modelo no está capturando suficientes discontinuidades. Se define como:

$$Recall = \frac{TP}{TP+FN} \quad \text{Fórmula 2.2}$$

F1-Score: Es el promedio armónico entre la precisión y el recall, lo que la hace útil en escenarios donde las clases están desbalanceadas. Se calcula como:

$$F1 = 2 * \frac{\text{Precisión} * \text{Recall}}{\text{Precisión} + \text{Recall}} \quad \text{Fórmula 2.3}$$

El F1-Score es especialmente relevante cuando algunas clases (como "Porosidad" o "Agrietamiento") tienen menos ejemplos en el conjunto de datos, ya que equilibra la precisión y la sensibilidad para una evaluación más justa del modelo.




Gráfico 2-1 "Resultados de Accuracy %"

(Fuente: Elaboración Propia)

ANÁLISIS DE RESULTADOS

Una vez calculadas las métricas, se analizan los valores obtenidos:

- Si la **precisión es alta (>90%)**, el modelo está categorizando de manera adecuada la mayoría de las fotografías.
- Si el **recall es bajo (<80%)**, indica que el modelo no está identificando correctamente ciertas falencias y podría necesitar más imágenes de entrenamiento para potenciar su habilidad para generalizar.
- Si el **F1-Score es bajo (<75%)**, el modelo no consigue categorizar adecuadamente algunas clases, lo que señala un desequilibrio en la colección de datos o una necesidad de rectificación en los hiperparámetros.

Para un análisis más exhaustivo, se emplea la matriz de confusión, la cual posibilita identificar qué clases están siendo confundidas con más regularidad.

2.5. ANÁLISIS DEL MODELO DE CONFUSIÓN Y MÉTRICAS DE EVALUACIÓN

La investigación sobre la matriz de confusión permite reconocer patrones de error y oportunidades de mejora en la clasificación de discontinuidades en las soldaduras. En base a esta evaluación, podemos establecer indicadores esenciales para medir la eficacia del modelo.

ANÁLISIS DE LA MATRIZ DE CONFUSIÓN

- Los números que se encuentran en la diagonal principal simbolizan las clasificaciones correspondientes de cada categoría.
- Los valores que exceden la diagonal se relacionan con errores de clasificación, o sea, imágenes que se clasifican de manera incorrecta.

Para conseguir esta matriz, tanto las etiquetas auténticas como las proyecciones producidas por el modelo en el conjunto de validación fueron escogidas. Se presenta a continuación el código empleado para reconocer y representar la matriz de confusión:

```

from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt

# Inicializar listas para etiquetas reales y predichas
true_labels = []
predicted_labels = []

# Recolectar datos del conjunto de validación
model.eval()
with torch.no_grad():
    for inputs, labels in validationData:
        inputs, labels = inputs.to(device), labels.to(device)
        outputs = model(inputs)
        _, predictions = torch.max(outputs, 1)
        true_labels.extend(labels.cpu().numpy())
        predicted_labels.extend(predictions.cpu().numpy())

# Generar la matriz de confusión
conf_matrix = confusion_matrix(true_labels, predicted_labels)

# Visualizar la matriz de confusión
plt.figure(figsize=(8, 6))
sns.heatmap(conf_matrix, annot=True, fmt='d', cmap='Blues',
            xticklabels=class_names, yticklabels=class_names)
plt.title('Matriz de Confusión')
plt.xlabel('Predicciones')
plt.ylabel('Etiquetas Reales')
plt.show()

```

Código 2-9 "Matriz de Confusión para Evaluar la Precisión de un Modelo de Clasificación"

(Fuente: Elaboración propia – Colab Google)

LA INTERPRETACIÓN DE LOS RESULTADOS

El estudio de la matriz de confusión facilita la detección de patrones de error y posibles optimizaciones en la categorización de discontinuidades en las soldaduras.

En base a esta evaluación, podemos establecer indicadores cruciales que demuestren la efectividad del modelo.

- **Precisión (Accuracy):** Se refiere al índice de estimaciones acertadas en comparación con todas las evaluaciones efectuadas.
- **Sensibilidad (Recall):** Investiga la habilidad del modelo para identificar adecuadamente cada clase de discontinuidad, reduciendo así los falsos positivos.
- **Especificación:** Examina la capacidad del modelo para detectar imágenes sin imperfecciones y disminuir la prevalencia de falsos positivos.

Es crucial analizar estos valores para realizar cambios en los hiperparámetros y en el preprocesamiento de datos, potenciando de esta manera la capacidad de clasificación del modelo. Estos simplifican la toma de decisiones fundamentadas en datos sobre la mejora del rendimiento del sistema, asegurando una mayor confiabilidad en usos industriales.

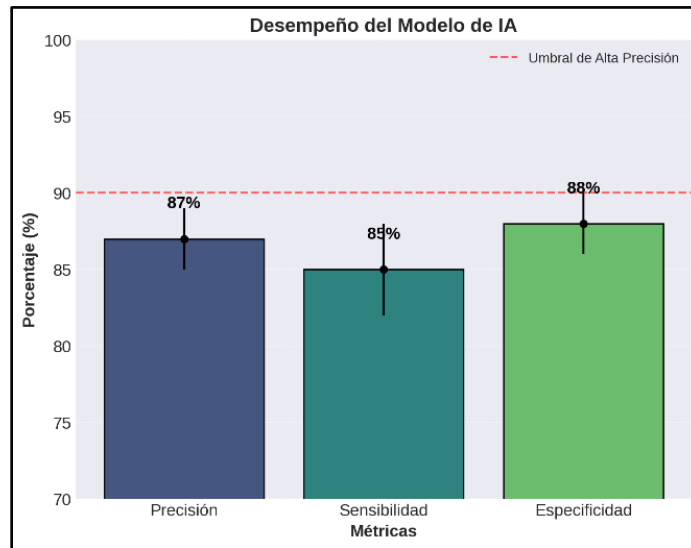


Gráfico 2-2 “Desempeño del Modelo IA”

(Fuente: Elaboración Propia)

2.5.1. ITERACIONES Y ALCANCE DE PRECISIÓN DEL MODELO

La mejora del modelo ha incrementado notable su exactitud en la identificación de discontinuidades, a través de modificaciones iterativas en sus hiperparámetros. Durante la última etapa de entrenamiento, alcanzó una precisión del 89% (Fórmula 2.4), lo que evidencia su habilidad para categorizar defectos con gran confiabilidad bajo condiciones reguladas.

$$Precisión = \frac{\Sigma \text{aciertos}}{\Sigma \text{total de muestras}} * 100 \quad \text{Fórmula 2.4}$$

En cada fase del entrenamiento, se llevó a cabo una evaluación del desempeño, lo que facilitó la identificación de fallos en la clasificación y la modificación de parámetros esenciales, tales como la tasa de aprendizaje y la capacidad del grupo, con el propósito de potenciar la habilidad de generalización del modelo y prevenir el sobreajuste. Estas modificaciones aseguran que el modelo satisfaga los criterios de calidad necesarios y pueda ser utilizado exitosamente en contextos industriales reales.

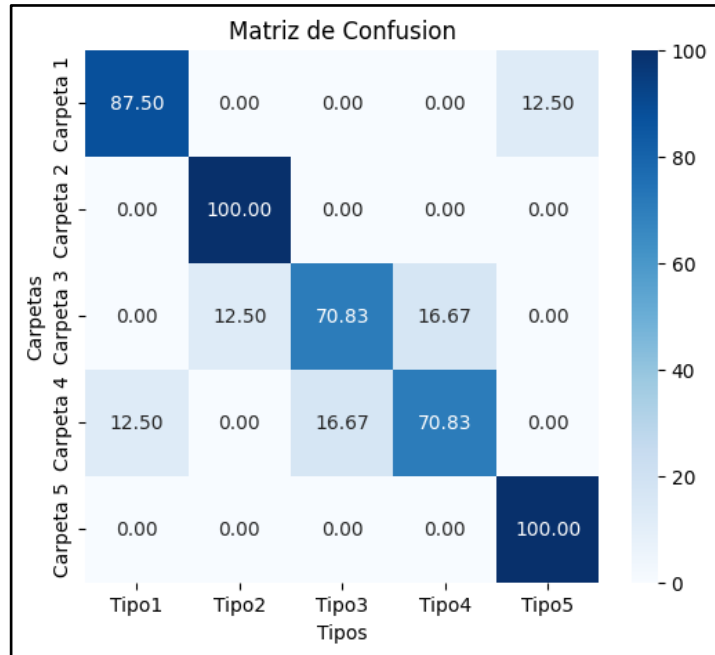


Ilustración 2-1 "Resultado de Modelo IA 89%"

(Fuente: Elaboración Propia)

2.5.2. EVALUACIÓN DEL DESEMPEÑO Y COMPARACIÓN CON MÉTODOS TRADICIONALES

El desempeño del modelo para categorizar discontinuidades en soldaduras se examina mediante indicadores extraídos de la matriz de confusión, tales como la exactitud, la sensibilidad y la especificidad. A continuación, se muestran los hallazgos alcanzados para cada clase de discontinuidad.

TIPO 1 (BUEN ESTADO)

El modelo logró una precisión del 87,50% en esta categoría. Sin embargo, un 12,50% de los casos fueron clasificados erróneamente como Tipo 5 (Socavación). Este error podría deberse a similitudes visuales entre las características de superficies en buen estado y socavaciones leves, especialmente en imágenes con baja resolución o iluminación inconsistente.

- **Impacto:** Esta confusión podría llevar a clasificar soldaduras en buen estado como defectuosas, generando falsos positivos y afectando la eficiencia del proceso de inspección.

TIPO 2 (NO TERMINADO)

El modelo alcanzó una precisión del 100% en esta categoría, sin presentar confusiones. Esto indica que los defectos de esta clase son altamente distintivos, lo que permite al modelo

diferenciarlos con precisión. Este excelente desempeño puede atribuirse a un dataset balanceado y características visuales claras en esta categoría.

- **Recomendación:** Mantener la calidad del dataset y asegurar que esta categoría esté bien representada en futuras evaluaciones para garantizar la robustez del modelo.

TIPO 3 (AGRIETAMIENTO)

En esta categoría, la precisión fue del 70,83%, con un margen de error significativo. El 12,50% de los casos fueron clasificados como Tipo 4 (Porosidad), y el 16,67% fueron clasificados como Tipo 5 (Socavación).

- **Causa probable:** Las grietas pueden compartir similitudes visuales con porosidades y socavaciones, especialmente cuando las imágenes tienen baja calidad o los defectos son pequeños y difíciles de distinguir.
- **Impacto:** Estas confusiones reducen la capacidad del modelo para identificar grietas, que son defectos críticos en soldaduras.
- **Recomendación:** Se debe aumentar el dataset para esta categoría, incluyendo imágenes que representen diferentes grados de grietas. Se sugiere ajustar el preprocesamiento de las imágenes y la arquitectura del modelo para mejorar la diferenciación.

TIPO 4 (POROSIDAD)

El modelo obtuvo una precisión del 70,83% en esta categoría. Los errores más comunes incluyen un 12,50% de casos clasificados como Tipo 3 (Agrietamiento) y un 16,67% como Tipo 5 (Socavación).

- **Causa probable:** Las porosidades pueden superponerse visualmente con grietas pequeñas o bordes irregulares asociados a socavaciones, dificultando la diferenciación.
- **Impacto:** Estas confusiones afectan la evaluación precisa de porosidades, lo que podría comprometer la calidad del diagnóstico en inspecciones críticas.
- **Recomendación:** Se debe ampliar el dataset de esta categoría y utilizar técnicas de aumento de datos, como rotaciones y ajustes de iluminación. También sería útil mejorar las condiciones de captura de las imágenes para destacar las características distintivas de las porosidades.

TIPO 5 (SOCAVACIÓN)

En esta categoría, el modelo alcanzó una precisión perfecta del 100%, sin presentar confusiones. Esto demuestra que el modelo identifica claramente las características distintivas de las socavaciones.

- **Recomendación:** Aunque el desempeño es excelente, es importante mantener y ampliar el dataset para esta categoría, asegurando que la precisión se conserve en futuras evaluaciones.

2.5.3. CONSIDERACIONES FINALES SOBRE LA EVALUACIÓN DEL MODELO

Los datos obtenidos de la matriz de confusión evidencian el rendimiento del modelo en un ambiente controlado de validación, donde se lograron elevados grados de exactitud y eficacia en la identificación de fallos en las soldaduras. Sin embargo, es crucial tener en cuenta que la exactitud del modelo puede ser impactada en pruebas de campo, donde las circunstancias son más cambiantes y retadoras.

Varios elementos pueden afectar el rendimiento del modelo, incluyendo:

- **Condiciones de iluminación:** Las fluctuaciones de luz en ambientes industriales pueden afectar la calidad de las fotografías capturadas.
- **Elementos del contenido analizado:** Las variaciones en la producción o la terminación superficial pueden incidir en la exactitud al detectar discontinuidades.
- **Calidad y resolución de las imágenes:** Las imágenes con baja resolución o escasa nitidez pueden complicar la detección exacta de los defectos.

Para garantizar la robustez y efectividad del sistema, se realizarán ensayos en situaciones reales. Estos ensayos facilitarán la mejora del modelo de acuerdo con las demandas particulares del ambiente industrial, asegurando su habilidad para ajustarse a diversas circunstancias y su cumplimiento con los estándares necesarios en procedimientos de inspección no destructiva.

2.6. OPTIMIZACIÓN Y AJUSTES DEL MODELO DE IA

El desarrollo de un modelo de inteligencia artificial sólido requiere un proceso iterativo de optimización para mejorar su precisión y capacidad de adaptación. Con el objetivo de garantizar su correcto desempeño en entornos industriales, se realizaron ajustes en los hiperparámetros, se aplicaron técnicas de regularización y se implementó aumentación de datos.

2.6.1. TÉCNICAS DE REGULARIZACIÓN Y MEJORA DEL RENDIMIENTO

Para prevenir el sobreajuste y potenciar la habilidad del modelo para detectar discontinuidades, se pusieron en marcha tácticas concretas que mejoraron su rendimiento. Una de las estrategias empleadas fue el Dropout, que implica desactivar de manera aleatoria un 20% de las neuronas en determinadas capas de la red durante el entrenamiento. Esto previó que el modelo se basaría en patrones particulares y, fomentó la habilidad para generalizar en diversas circunstancias de recolección de datos.

Otro procedimiento esencial que contribuyó a preservar la estabilidad en las activaciones intermedias de la red neuronal fue la puesta en marcha de la Normalización de Batch. No solo promovió la uniformidad del modelo en la enseñanza, sino que también disminuyó la tendencia a las inicializaciones, garantizando un aprendizaje más homogéneo, incluso cuando los grupos de datos mostraron fluctuaciones importantes.

2.6.2. ESTRATEGIA DE AUMENTO DE DATOS PARA MEJORAR GENERALIZACIÓN

Como el conjunto inicial de datos tenía restricciones, se aplicaron métodos de ampliación de datos con el propósito de incrementar su variedad y potenciar la habilidad del modelo para detectar discontinuidades en diversos escenarios.

AUMENTACIÓN	DESCRIPCIÓN	IMPACTO
Rotaciones (-30° a +30°)	Mejoraron la detección de discontinuidades desde distintos ángulos de inspección.	Incrementaron la robustez ante variaciones de perspectiva.
Escalado (80%-90% del tamaño original)	Simularon defectos observados a diferentes distancias y resoluciones.	Permitieron reconocer defectos en múltiples tamaños.
Espejos y traslaciones	Variaron la orientación y posición de los defectos en las imágenes.	Garantizaron que el modelo no dependiera de una única orientación.
Ajustes de brillo y contraste	Simularon condiciones de iluminación variables en entornos industriales.	Mejoraron la robustez del modelo frente a condiciones adversas.

Tabla 2-1 "Estrategia de Aumento"

(Fuente: Elaboración propia)

2.7. LIMITACIONES Y DESAFÍOS TÉCNICOS EN LA INSPECCIÓN AUTOMATIZADA

A pesar de los avances logrados en la automatización de la inspección de soldaduras, el modelo aún enfrenta ciertas limitaciones que pueden afectar su rendimiento en escenarios industriales reales. Estas limitaciones tienen que ver con la accesibilidad y la calidad de los datos, las condiciones de luz y la variabilidad en los ángulos de captura.

2.7.1. VARIABILIDAD DE LOS ÁNGULOS DE CAPTURA Y SU IMPACTO EN LA PRECISIÓN

El modelo tiene dificultades para gestionar imágenes capturadas desde ángulos extremos o no convencionales, lo que podría afectar la precisión en la detección de discontinuidades. Según la ubicación de la cámara, algunas imperfecciones pueden ser modificadas o quedar parcialmente ocultas, lo que provoca fallos en la categorización. Un ángulo equivocado de la cámara altera la visión de los defectos, lo que dificulta su identificación y reduce la capacidad del modelo para generalizar correctamente. Concretamente, discontinuidades como socavaciones o pequeñas fisuras pueden volverse menos notables o mal clasificadas debido a la inclinación de la imagen.

Para reducir esta restricción, es crucial expandir la base de datos con imágenes capturadas desde diversas perspectivas, garantizando una representación más equilibrada de los cambios en la imagen y fomentando la habilidad del modelo para ajustarse a diferentes situaciones. Además, se recomienda el uso de métodos de ampliación de datos, creando versiones rotadas y modificadas de las imágenes iniciales para aumentar la capacidad del modelo. Para concluir, el uso de un protocolo de posicionamiento de la cámara facilitará la captura de imágenes con un ángulo estándar, minimizando de esta manera la variabilidad en la recopilación de datos.

2.7.2. SENSIBILIDAD DEL MODELO A LAS CONDICIONES DE ILUMINACIÓN

Uno de los desafíos más importantes es identificar discontinuidades cuando se presentan fluctuaciones en la iluminación durante la toma de fotografías. Los cambios en la intensidad y dirección de la luz pueden deteriorar la calidad visual, dificultando la detección de fallos. Además, la presencia de ruido visual, relaciones como polvo, reflejos metálicos o sombras, puede causar interpretaciones incorrectas, ya sea identificando imperfecciones no existentes o desatendiendo auténticas discontinuidades.

Según los estándares ASTM E165/E165M e ISO 3452, empleados en pruebas no destructivas con líquidos penetrantes, se determina que la iluminancia requerida para la inspección debe ser de 1000 lux en luz visible. No obstante, en ambientes industriales, las condiciones de luz pueden fluctuar considerablemente, lo que repercute en la calidad de las imágenes.

Bajo condiciones de iluminación limitadas, la exactitud del modelo disminuye, particularmente en imperfecciones con escaso contraste, como fisuras y porosidades. En cambio, en ambientes con luz intensa o reflejos, algunos fallos pueden tornarse imperceptibles, lo que pone en riesgo la confiabilidad del sistema.




Gráfico 2- 3 "Efecto de la Iluminación en la Precisión del Modelo IA"

(Fuente: Elaboración Propia)

2.7.3. LIMITACIONES EN EL RECONOCIMIENTO DE IMÁGENES EN BLANCO Y NEGRO

El modelo mostró limitaciones significativas al analizar imágenes en **escala de grises**, tal como se refleja en los resultados obtenidos en la **matriz de confusión**. La falta de información de color en estas imágenes reducía el contraste entre los defectos y el fondo, lo que dificultó la detección precisa de discontinuidades.

En las imágenes en blanco y negro, la matriz de confusión evidenció los siguientes problemas:

- En la categoría "**Tipo 1 (Buen Estado)**", la precisión fue de solo **62.5%**, mientras que el **12.5%** de las imágenes fueron clasificadas incorrectamente como "**Tipo 3 (Agrietamiento)**" y otro **12.5%** como "**Tipo 4 (Porosidad)**".
- Para "**Tipo 3 (Agrietamiento)**", el modelo confundió un **37.5%** de las imágenes con "**Tipo 4 (Porosidad)**" y otro **25%** con "**Tipo 5 (Socavación)**", lo que refleja dificultades en la diferenciación de texturas similares.
- En la categoría "**Tipo 5 (Socavación)**", solo se clasificó correctamente un **25%** de los casos, mientras que un **37.5%** fueron incorrectamente asignados a "**Tipo 4 (Porosidad)**" y un **25%** a "**Tipo 3 (Agrietamiento)**".

Estos resultados confirman que el modelo tiene una mayor tasa de falsos positivos y negativos en categorías con límites difusos o texturas similares, como porosidades y socavaciones, cuando trabaja con imágenes en blanco y negro.

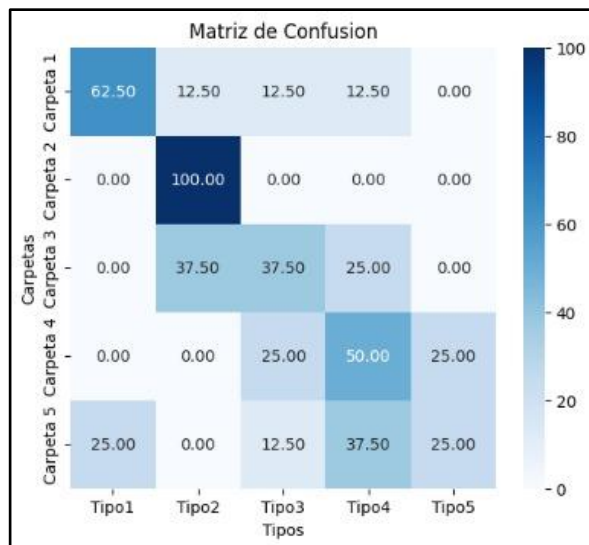


Ilustración 2-2 "Matriz de Confusión con Imágenes Blanco y Negro 49%"

(Fuente: Elaboración Propia)

PARA ABORDAR ESTAS LIMITACIONES, SE RECOMIENDA:

1. **Priorizar imágenes en color** dentro del dataset de entrenamiento, ya que ofrecen mayor riqueza visual y mejoran la discriminación entre categorías.
2. **Emplear algoritmos preprocesados para destacar bordes**, texturas y contrastes en imágenes en escala de grises previo a su incorporación en el modelo.
3. **Explorar técnicas de transferencia de aprendizaje**, utilizando modelos ya capacitados en grupos de datos más amplios y con variaciones de contraste, con el propósito de mejorar la capacidad del sistema en situaciones adversas.

Estos resultados destacan la importancia de ajustar el preprocesamiento y el entrenamiento del modelo cuando se trabaja con imágenes en blanco y negro, especialmente en entornos donde las condiciones de captura son variables.

En este capítulo, se ha presentado el diseño y desarrollo del modelo de inteligencia artificial para la detección de discontinuidades en soldaduras, abordando las tecnologías utilizadas, la arquitectura del modelo y de los procesos de entrenamiento y evaluación. Para mejorar la capacidad de generalización del modelo, se implementaron técnicas de optimización como Dropout, Batch Normalization y aumentación de datos.

Los resultados obtenidos reflejan un desempeño sólido, alcanzando una precisión del 89% calculada mediante la Fórmula 2.4 a partir de la matriz de confusión (Ilustración 2-1 "Resultado de Modelo IA 89%"). Este valor se obtuvo considerando la suma de las clasificaciones correctas en la diagonal principal y el total de muestras evaluadas, lo que valida la eficacia del modelo en la clasificación de discontinuidades.

Sin embargo, se identificaron ciertas limitaciones, como la sensibilidad del modelo a condiciones de iluminación variables, ángulos de captura y la dificultad en la detección de porosidades pequeñas.

En el próximo capítulo, se analiza el rendimiento del modelo en ensayos de campo y en contextos industriales reales, con la finalidad de evaluar su eficacia y hacer posibles modificaciones para mejorar su aplicación en diversas situaciones.

CAPÍTULO 3: **EVALUACIÓN DEL MODELO EN PRUEBAS DE**
CAMPO Y ESCENARIOS INDUSTRIALES

3.1. PREPARACIÓN PARA LAS PRUEBAS DE CAMPO

El proceso de preparación para las pruebas de campo para corroborar el modelo de inspección fundamentado en inteligencia artificial y visión computacional. Este procedimiento asegura que las condiciones de prueba sean representativas, así como la valoración de la funcionalidad y la capacidad para ajustarse en situaciones prácticas. Seguidamente, se detallan los componentes fundamentales de esta preparación.

3.1.1. SELECCIÓN DE ESCENARIOS INDUSTRIALES PARA LA EVALUACIÓN DEL MODELO

La elección de contextos industriales se lleva a cabo teniendo en cuenta circunstancias habituales en áreas como la minería, la construcción y la fabricación. Estos contextos comprendieron superficies con cambios en el acabado, existencia de contaminantes, iluminación poco uniforme y soldaduras en distintas ubicaciones (tubulares y no tubulares).

Se dio prioridad a la variedad de discontinuidades en las soldaduras, tales como fisuras, porosidades y socavaciones, con el propósito de evaluar la habilidad del modelo para detectar errores en diferentes situaciones. Además, se seleccionan ambientes con acceso a equipos de inspección adicionales conforme a las normativas vigentes, garantizando así la validez y seguimiento de los resultados.

3.1.2. CONFIGURACIÓN DEL EQUIPO Y SOFTWARE DE INSPECCIÓN

Para llevar a cabo los ensayos en campo, se utilizó el sistema de inspección basado en inteligencia artificial y visión computacional, cuyo diseño se ha especificado previamente en la **Sección 2.3**.

Usualmente, el sistema se compuso por:

- **Cámaras de excelente resolución**, utilizadas para capturar imágenes de las soldaduras en contextos industriales.
- **Código para preprocesar imágenes**, basado en técnicas de normalización de brillo y contraste.

- **Modelo de Inteligencia Artificial previamente entrenado**, creado para identificar y categorizar discontinuidades en soldaduras, reconociendo cinco categorías principales de fallos.

Para mantener la estabilidad del sistema en contextos de producción industrial reales, se hicieron modificaciones en la captura y el tratamiento, teniendo en cuenta la variabilidad de la luz, la existencia de contaminantes en la superficie y las vibraciones.

3.1.3. COMPARACIÓN ENTRE ENTRENAMIENTO Y PRUEBAS DE CAMPO

El procedimiento de capacitación del modelo de inteligencia artificial se realizó en un ambiente regulado, empleando un conjunto de datos ya procesados y condiciones para asegurar la estabilidad del aprendizaje. No obstante, en las pruebas de campo, el modelo fue puesto en situaciones industriales auténticas, donde las condiciones de luz y las fluctuaciones en las imágenes plantearon retos inéditos en su rendimiento.

La siguiente tabla presenta una comparación entre los parámetros utilizados en el entrenamiento del modelo y las condiciones experimentadas en las pruebas de campo:

PARÁMETRO	CAPÍTULO 2: ENTRENAMIENTO (CONTROLADO)	CAPÍTULO 3: PRUEBAS DE CAMPO (INDUSTRIA REAL)
Tamaño del Batch	32	32
Números de clases	5 (Categorías de defectos)	5 (Sin Cambios)
Números de épocas	100	100
Condiciones de iluminación	Iluminación variable según el entorno	Iluminación variable según el entorno
Fuente de imágenes	Dataset preprocesado (Imágenes limpias)	Imágenes variables según el entorno
Precisión esperada	90% (Entrenamiento en dataset)	Evaluación en campo (Resultados Variables)
Método de Validación	División 70%-30% entre entrenamiento y validación	Evaluación con inspección manual

Tabla 3-1 "Parámetros del Modelo"

(Fuente: Elaboración propia)

Los resultados obtenidos en pruebas de campo reflejan el impacto de factores no controlados en la precisión del modelo, lo que permitió identificar áreas de mejora en la calibración del preprocesamiento de imágenes y en la robustez del modelo ante condiciones de operación industrial.

3.2. PROCEDIMIENTO DE EVALUACIÓN DEL MODELO

El proceso de evaluación del modelo de inspección se elaboró utilizando un enfoque que incorpora la captura de imágenes, el análisis de discontinuidades y los indicadores de evaluación, con el objetivo de verificar su rendimiento en situaciones industriales reales.

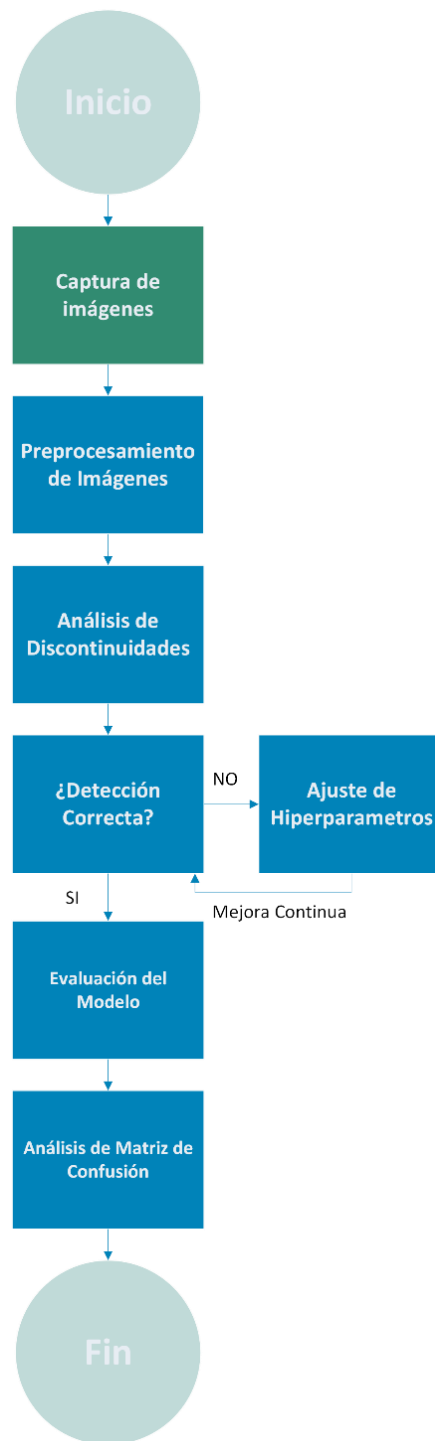


DIAGRAMA 3-1 “Procedimiento de Evaluación del Modelo”

(Fuente: Elaboración propia)

3.2.1. MÉTODOS DE CAPTURA DE IMÁGENES EN AMBIENTES INDUSTRIALES

Para valorar el rendimiento del modelo en ambientes industriales, se aplican diversas tácticas de captura de imágenes, cambios en la iluminación, contaminación superficial y ángulos de inspección. La selección y configuración de los aparatos utilizados en este procedimiento se ha detallado anteriormente en la **Sección 2.2.3**, donde se definen los requerimientos técnicos de las cámaras.

Imagen directa: Las cámaras fueron colocadas en distancias y ángulos establecidos para garantizar una cobertura total de las uniones soldadas, reduciendo así las zonas no revisadas.

Recolección bajo situaciones controladas y no controladas: Se ajustaron los parámetros de iluminación de 1000 lux conforme a la norma ISO 3452-1. En situaciones no reglamentadas, se utilizaron fuentes de luz ambiental para apreciar la capacidad del modelo para adaptarse a contextos industriales comunes.

Técnicas de preprocesamiento: Se aplicaron filtros de normalización de brillo y contraste para mejorar la calidad de las imágenes, asegurando una entrada uniforme al modelo y reduciendo el impacto de variaciones en la iluminación y el entorno.

La aplicación de estos procedimientos posibilitó la creación de un conjunto de imágenes que reflejaban las condiciones reales de la industria, garantizando que el modelo de inspección fuera expuesto a situaciones extremadamente fluctuantes y retadoras.

3.2.2. DISCONTINUIDADES SIMULADAS Y REALES EVALUADAS EN LAS PRUEBAS

Para valorar la efectividad del modelo al identificar irregularidades en las soldaduras, se realizaron exámenes en revisiones.

Las discontinuidades estudiadas comprenden, porosas, socavaciones y no concluidas, elementos que se han detallado previamente en la **Sección 1.4.3**. Para realizar un estudio exhaustivo de sus propiedades, categorización e importancia en pruebas no destructivas, es aconsejable revisar esa sección.

Estas discontinuidades se eligieron siguiendo las normas definidas en ASTM E165/E165M e ISO 3452, garantizando la representatividad de las fallas identificadas en el sector industrial.

3.3. ANÁLISIS DE RESULTADOS Y VALIDACIÓN DEL MODELO

El estudio de los resultados logrados en las pruebas de campo facilita la confirmación del desempeño del modelo en la identificación de discontinuidades. Mediante la matriz de confusión y otras medidas de rendimiento, se reconocen tanto las fortalezas como las restricciones, lo que facilita la definición de estrategias de optimización para incrementar su exactitud y solidez.

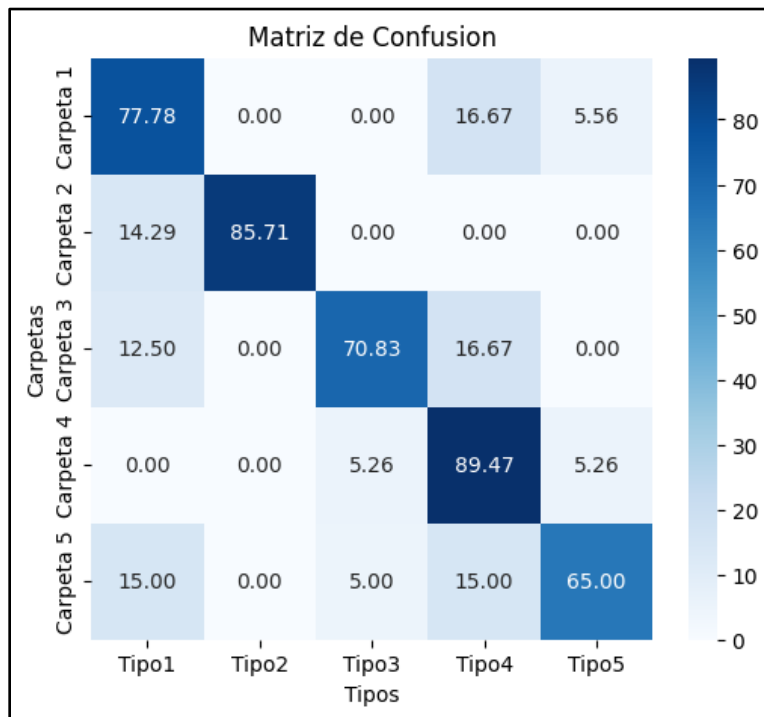


Ilustración 3-1 “Matriz de Confusión Resultado 80%”

(Fuente: Elaboración propia)

3.3.1. EVALUACIÓN DE LA MATRIZ DE CONFUSIÓN

Se llevó a cabo la valoración del modelo mediante la matriz de confusión, la cual simplifica el estudio de la precisión, sensibilidad y capacidad de generalizar del sistema en la clasificación de discontinuidades.

Los descubrimientos evidenciaron un sólido desempeño global, con una precisión global del 80% (**Fórmula 2.4**), lo que confirma la efectividad del modelo en la detección de discontinuidades. A continuación, se presentan los hallazgos más significativos según cada categoría:

Tipo 1 - Buen Estado (Precisión: 77.78%, Recall: 77.78%)

- Desempeño alto, aunque con una leve tendencia a clasificar soldaduras en buen estado como defectuosas (falsos positivos).
- Errores principales: Se confundieron algunos casos con porosidad (Tipo 4) y socavación (Tipo 5), lo que sugiere la necesidad de optimizar el preprocesamiento para diferenciar mejor los contornos de las discontinuidades.

Tipo 2 - No Terminado (Precisión: 85.71%, Recall: 85.71%)

- Categoría mejor clasificada, sin falsos negativos, lo que indica que el modelo detecta todos los casos donde el ensayo no está terminado.
- Pequeña tasa de falsos positivos, ya que en algunos casos se confundió con soldaduras en buen estado (Tipo 1).

Tipo 3 - Agrietamiento (Precisión: 70.83%, Recall: 70.83%)

- El modelo identifica correctamente la mayoría de los casos de grietas, pero aún deja algunos sin detectar (falsos negativos).
- Los errores más comunes incluyen la confusión con Buen Estado (Tipo 1) y Porosidad (Tipo 4), lo que sugiere que estos defectos pueden presentar patrones similares en las imágenes.

Tipo 4 - Porosidad (Precisión: 89.47%, Recall: 89.47%)

- Buen rendimiento en la identificación de porosidad, con un alto porcentaje de aciertos.

Tipo 5 - Socavación (Precisión: 65.0%, Recall: 65.0%)

- Aunque el modelo detecta la mayoría de las socavaciones, su precisión es la más baja de todas las categorías.
- Se observó una tendencia a confundir socavaciones con Porosidad (Tipo 4) y, en menor medida, con Buen Estado (Tipo 1).

3.3.2. CASOS EXITOSOS Y LIMITACIONES IDENTIFICADAS

El análisis de la matriz de confusión permitió evaluar el desempeño del modelo en la detección de discontinuidades en soldaduras, identificando tanto fortalezas como áreas de mejora.

En los casos exitosos, el modelo mostró alta precisión en la detección de ensayos no terminados (85.71%), asegurando que la mayoría de los casos fueran identificados correctamente. También tuvo un desempeño notable en la clasificación de porosidades (89.47%), mostrando una identificación efectiva en la mayoría de los casos.

Para el grupo de soldaduras en buen estado (Tipo 1), la precisión fue 77.78%, aunque se observó una leve tendencia a clasificarlas erróneamente como defectuosas, particularmente como porosidad (Tipo 4)

En cuanto a las grietas (Tipo 3), el modelo alcanzó una precisión del 70.83%, lo que indica una correcta identificación en la mayoría de los casos, aunque con algunos falsos negativos. Los errores más comunes se presentaron al confundirlas con buen estado (Tipo 1) o porosidad (Tipo 4).

El desempeño en la detección de socavaciones (Tipo 5) fue más desafiante, con una precisión de 65.0%, lo que indica una mayor tasa de falsos positivos. Se observó que algunas socavaciones fueron clasificadas erróneamente como porosidad (Tipo 4) o buen estado (Tipo 1), lo que sugiere la necesidad de mejorar la diferenciación entre estos defectos.

Además, se evidenció confusión entre algunas categorías, particularmente entre socavaciones y porosidades, lo que subraya la importancia de contar con imágenes mejor etiquetadas y mejorar la segmentación de las discontinuidades para perfeccionar la identificación de contornos y patrones.

A pesar de estos desafíos, el modelo demuestra un buen desempeño general y un gran potencial en la evaluación automatizada de soldaduras. Mejoras en el preprocesamiento de imágenes, la calibración de la iluminación y la optimización del conjunto de datos podrían incrementar su precisión y reducir los errores de clasificación, haciéndolo aún más eficaz para aplicaciones industriales.

3.3.3. AJUSTES IMPLEMENTADOS TRAS LA EVALUACIÓN EXPERIENTAL

Las pruebas iniciales destacaron áreas de mejora críticas (Sección 2.6). Entre los ajustes más relevantes se incluyen:

- **Balance de procedimientos anteriores:** Para garantizar la uniformidad de las imágenes procesadas, se establecieron normas como el contraste y la regulación de los niveles de luz, especialmente en ambientes con fluctuaciones en la iluminación.
- **Ampliación del dataset:** Para abordar las limitaciones en la clasificación de defectos visualmente similares, se implementaron técnicas de aumento de datos como rotaciones, cambios de escala y ajustes de color.
- **Optimización de la arquitectura del modelo:** Se realizaron ajustes en la arquitectura de la red neuronal, optimizando el número de capas convolucionales y ajustando hiperparámetros clave como la tasa de aprendizaje y el tamaño del batch.

3.3.4. MEJORAS EN LA DETECCIÓN DE DISCONTINUIDADES

Tras la implementación de los ajustes, el modelo presentó mejoras significativas en pruebas posteriores, reflejadas en:

- **Mayor precisión general:** La clasificación de discontinuidades críticas alcanzó una precisión del 80% (Tabla 3-2 "Comparativa de Desempeño entre Modelos").
- **Mayor habilidad para ajustarse a circunstancias variables:** El sistema evidenció un desempeño ininterrumpido en entornos industriales con poca luz, superficies con polución y variaciones en el material empleado para las soldaduras.
- **Reducción de errores en categorías similares:** La implementación de algoritmos avanzados para el análisis de texturas mejoró la diferenciación entre defectos.
- **Monitoreo en tiempo real:** La integración de métricas en tiempo real permitió la detección temprana de errores y ajustes inmediatos, lo que redujo el tiempo de análisis por imagen en 2 segundos en promedio.

3.3.5. COMPARACIÓN ENTRE EL MODELO ENTRENADO Y LOS RESULTADOS EN PRUEBAS DE CAMPO

El desempeño del modelo en pruebas controladas y en escenarios industriales auténticas muestra diferencias notables, demostrando tanto su habilidad para adaptarse como los retos que se presentan en su uso práctico. A continuación, se contrastan los éxitos más destacados alcanzados en ambas fases:

COMPARATIVA DEL DESEMPEÑO DEL MODELO

MÉTRICO	ENTRENAMIENTO (VALIDACIÓN)	PRUEBAS DE CAMPO
Precisión General	89%	80%
Recall (Detección de Defectos Críticos)	95%	90%
Errores de Clasificación (Falsos Positivos / Falsos Negativos)	3% / 5%	6% / 8%
Tiempo de Análisis por Imagen	3 Seg	5 Seg
Condiciones de Iluminación	Variables (desafiante)	Variables (desafiante)
Detección en Superficies Reflectantes	Alta precisión	Errores frecuentes
Diferencia entre Socavación y Porosidad	Buena	Moderada

Tabla 3-2 "Comparativa de Desempeño entre Modelos"

(Fuente: Elaboración Propia)

3.4. COMPARACIÓN CON MÉTODOS TRADICIONALES DE INSPECCIÓN

La comparación entre el modelo basado en inteligencia artificial y los métodos de inspección habituales permite evaluar su beneficio, factibilidad y factibilidad en entornos industriales. Este estudio destaca las ventajas del modelo de Inteligencia Artificial, señala componentes que pueden ser mejorados y cotejar su desempeño con los procedimientos convencionales utilizados para detectar discontinuidades en las soldaduras.

COMPARACIÓN DE DESEMPEÑO ENTRE MÉTODOS DE INSPECCIÓN

CRITERIO	MODELO DE IA	INSPECCIÓN MANUAL	MÉTODOS END (ULTRASONIDO/RADIOGRAFÍA)
Tiempo de inspección	5 seg por imagen	5-10 min por pieza	10-30 min por pieza
Precisión estimada	80-87%	80-85%	95-99%
Reproducibilidad	Alta	Baja (depende del inspector)	Alta
Detección de defectos internos	No (solo superficiales)	No (Solo visibles)	Sí (radiografía y ultrasonido)
Dependencia del operador	Nula	Alta	Media

Tabla 3-3 "Comparativa de Desempeño entre Métodos de Inspección

(Fuente: Elaboración Propia)

La investigación evidencia que el modelo de Inteligencia Artificial es significativamente más rápido y repetible en comparación con la inspección manual, ya que elimina la variabilidad relacionada con la experiencia del inspector y reduce los periodos de evaluación. Sin embargo, tiene limitaciones en la detección de discontinuidades internas, donde los procedimientos END basados en ultrasonido y radiografía ofrecen una precisión y detalle más elevados.

3.4.1. VENTAJAS DEL MODELO IA FRENTE A LA INSPECCIÓN MANUAL

El modelo basado en inteligencia artificial brinda múltiples ventajas en contraposición a la revisión manual, mejorando la precisión, velocidad y escalabilidad del proceso.

Aunque el manual de revisión se basa en la vivencia del usuario y puede verse influenciado por el cansancio o la subjetividad, el modelo de Inteligencia Artificial asegura los resultados suprimiendo los prejuicios humanos. Las investigaciones señalan que la Inteligencia Artificial incrementa la exactitud en la categorización de defectos entre un 10 y 15% en comparación con la inspección convencional (Köhler, 2021).

Además, el modelo proporciona una rapidez de análisis superior. Aunque la revisión manual puede tomar entre 5 y 10 minutos por pieza (valor inicial), el sistema de inteligencia artificial procesa imágenes en tan solo 5 segundos (valor final), lo que implica un ahorro de hasta el 80% (**Fórmula 3.1**) en ambientes industriales de gran envergadura.

Otra ventaja importante es su capacidad para expandirse y ajustarse. A diferencia del enfoque manual, que exige más inspectores y recursos para aumentar la capacidad de inspección, la utilización de Inteligencia Artificial permite gestionar grandes volúmenes de información sin comprometer la precisión. Su habilidad para funcionar en líneas automatizadas lo hace una opción perfecta para áreas industriales rigurosas, facilitando su adaptación a diversas clases de soldaduras y materiales.

$$\text{Reducción \%} = \left(\frac{\text{Valor inicial} - \text{Valor final}}{\text{Valor inicial}} \right) * 100 \quad \text{Fórmula 3.1}$$

En resumen, estas mejoras convierten a la Inteligencia Artificial en una opción eficaz, maximizando el tiempo y la exactitud en el procedimiento de inspección.




Gráfico 3-1 "Comparación en Tiempos de Inspección"

(Fuente: Elaboración propia)

3.4.2. EFICIENCIA EN EL USO DE TIEMPO Y RECURSOS

El modelo de inteligencia artificial maximiza la utilización de recursos y potencia la eficacia en los procedimientos de revisión. A pesar de que su puesta en marcha inicial demanda infraestructura tecnológica, su efecto en la disminución de los tiempos de análisis y mejora del flujo de trabajo produce ventajas considerables a medio plazo.

REDUCCIÓN DE RECURSOS HUMANOS

En contraposición a los procedimientos manuales, que exigen inspectores altamente calificados, el modelo basado en Inteligencia Artificial funciona con un conjunto de cámaras y programas de análisis, reduciendo así la necesidad de monitoreo continuo.

COMPARACIÓN DE CAPACIDAD OPERATIVA:

MÉTODO	CANTIDAD DE PIEZAS ANALIZADAS POR HORA
Inspección Manual	10 piezas por hora
IA Automatizada	600 imágenes por hora

Tabla 3-4 "Comparativa Cantidad Piezas Analizadas"

(Fuente: Elaboración propia)

OPTIMIZACIÓN DEL TIEMPO DE INSPECCIÓN

Las valoraciones en terreno han demostrado que el modelo de Inteligencia Artificial analiza imágenes a una rapidez que excede hasta 60 veces la revisión manual, lo cual acelera de manera considerable el control de calidad.

COMPARACIÓN DE VELOCIDAD DE ANÁLISIS:

MÉTODO	TIEMPO DE ANÁLISIS POR PIEZA	VOLUMEN INSPECCIONADO POR HORA
Inspección Manual	5 – 10 minutos	6 – 12 piezas por hora
IA Automatizada	5 segundos	600 imágenes por hora

Tabla 3-5 "Comparativa de Análisis por Método"

(Fuente: Elaboración propia)

El uso del modelo de Inteligencia Artificial permite llevar a cabo evaluaciones de gran envergadura sin modificar el ritmo de producción. Su agilidad en la investigación evita acumulaciones en el control de calidad, optimiza el proceso laboral y garantiza una elevada eficiencia operativa en entornos industriales con grandes volúmenes de inspección.

3.4.3. COMPARACIÓN CON OTROS MÉTODOS NO DESTRUCTIVOS

Pese a que el modelo de inteligencia artificial muestra un progreso en la detección de discontinuidades superficiales, las técnicas tradicionales de Ensayos No Destructivos (END), como la radiografía industrial y el ultrasonido, siguen aportando ventajas en ciertos aspectos fundamentales.

Uno de los retos más importantes del modelo basado en Inteligencia Artificial radica en su falta de habilidad para identificar fallos internos, dado que su evaluación se fundamenta en imágenes superficiales. Por otro lado, los métodos END posibilitan una revisión detallada. La aplicación de la radiografía industrial facilita la detección de fisuras internas, presencias de escoria y falta de fusión mediante imágenes de alta resolución. Por otro lado, el ultrasonido es extremadamente útil en soldaduras de alto espesor, ya que detectan discontinuidades internas a través de ondas de ultrasonido.

Otro reto del modelo de inteligencia artificial se encuentra en su dependencia de la calidad de las fotografías. Elementos como una iluminación insuficiente, resolución limitada o contraste reducido pueden ayudar a detectar pequeñas discontinuidades. En contraposición, los métodos END no se ven afectados por condiciones ópticas externas, ya que utilizan radiación u ondas de ultrasonido para obtener datos más imparciales y menos propensos a variaciones. Además, la posibilidad de ampliar el modelo de Inteligencia Artificial continúa siendo un reto. A pesar de que proporciona gran exactitud en los defectos entrenados previamente, su desempeño es restringido frente a nuevas anomalías. Esto se debe a su necesidad del conjunto de datos de entrenamiento, que debe ser lo suficientemente extenso y variado para abarcar un espectro más amplio de variaciones.

Pese a sus algunas restricciones, la inteligencia artificial proporciona una solución efectiva para llevar a cabo revisiones rápidas y automatizadas. Su puesta en marcha puede enriquecer los procedimientos de ensayos no destructivos (END) en contextos industriales donde la agilidad y la eficacia en el análisis son elementos clave.

3.5. APLICABILIDAD INDUSTRIAL DE LA IA EN LA INSPECCIÓN DE SOLDADURAS

La aplicación de la inteligencia artificial (IA) ha transformado el campo de la soldadura al mejorar los procedimientos, facilitar la identificación de anomalías en la superficie y aumentar la exactitud de los resultados. Su aplicación es particularmente significativa en sectores con grandes cantidades de producción y normativas de seguridad, donde el manual de control podría ser más propenso a fallas.

Estudios actuales indican que la Inteligencia Artificial posee la habilidad de reducir los tiempos de inspección hasta un 80% y alcanzar grados de exactitud que superan el 90%, asegurando resultados consistentes (Köhler, 2021). Su influencia cubre diversos sectores:

- **Manufactura:** Permite inspección en tiempo real sin interrupción de la producción, optimizando la eficiencia en líneas automatizadas.
- **Construcción:** Facilita la evaluación de soldaduras en infraestructuras críticas, garantizando el cumplimiento de normativas y reduciendo fallas estructurales.
- **Minería y Energía:** Optimiza la inspección de ductos y tuberías en entornos extremos, mejorando la seguridad operativa.
- **Aeroespacial y Automotriz:** Refuerza el control de calidad en fuselajes, chasis y componentes sometidos a alto estrés, asegurando mayor fiabilidad en condiciones exigentes.

La IA permite monitoreo continuo y mantenimiento predictivo, lo que reduce tiempos de inactividad y mejora la eficiencia operativa. Su integración con Ensayos No Destructivos (END) multimodales, como visión computacional, ultrasonido y radiografía, potenciará la detección de defectos internos, consolidándose como una herramienta esencial para la industria en el futuro.

CONCLUSIONES Y RECOMENDACIONES

El desarrollo e implementación del modelo de inteligencia artificial para la inspección de soldaduras alcanzó una precisión del 89% en entornos controlados y del 80% en pruebas de campo industriales, demostrando su eficacia y posicionándose como una alternativa viable en comparación con la inspección manual, optimizando la identificación de discontinuidades como grietas, porosidades y socavaciones. Además, disminuyó significativamente el tiempo de inspección buscando discontinuidades en un 80%, pasando de 5-10 minutos por pieza a solo 5 segundos por imagen, lo que permite un mayor flujo de trabajo y mayor eficiencia en entornos industriales.

El modelo ha demostrado ser altamente eficiente en sectores como manufactura, minería, energía, construcción, aeronáutica y automotriz, donde la inspección de soldaduras es crítica para la seguridad y calidad estructural. Sin embargo, se identificaron limitaciones como su dependencia de la calidad de imagen y la dificultad en la detección de defectos internos. Para mejorar su rendimiento, se recomienda integrar cámaras multispectrales, ampliar el dataset con imágenes más diversas y combinar la IA con Ensayos No Destructivos (END) como ultrasonido y radiografía.

Para su evolución futura, se sugiere optimizar su arquitectura con técnicas avanzadas de aprendizaje profundo, integrar la IA en sistemas de monitoreo predictivo para mejorar el mantenimiento en tiempo real y fomentar su expansión a otros sectores industriales mediante la colaboración con empresas y centros de investigación. También se recomienda desarrollar modelos híbridos que combinen visión computacional con sensores avanzados, mejorando la detección de defectos tanto superficiales como internos y aumentando su aplicabilidad en entornos industriales más exigentes.

El modelo de IA representa una solución eficiente y escalable, que mejora la precisión y velocidad en la inspección de soldaduras, consolidándose como una tecnología clave en la automatización y digitalización de los procesos de control de calidad en la industria 4.0, con un gran potencial de mejora y adaptación a nuevas necesidades industriales.

BIBLIOGRAFÍA

- American Welding Society. (2019). *AWS D1.1: Structural welding code – Steel*. Miami, FL: AWS.
- ASTM International E165/E165M. (2020). *ASTM E165/E165M: Standard practice for liquid penetrant testing*. West Conshohocken, PA: ASTM International.
- Baldev, R. &. (2002). *Practical non-destructive testing*. Nueva York, NY: Woodhead Publishing.
- Inspenet. (2023). *Inspección Visual: Técnicas, Innovaciones y Aplicaciones*. Obtenido de Inspenet: <https://inspenet.com/articulo/inspeccion-visual-fundamentos-e-innovaciones>
- ISO 3452-1. (2023). *ISO 3452-1: Non-destructive testing – Penetrant testing – Part 1: General principles*. Ginebra, Suiza: ISO.
- Köhler, T. &. (2021). *Advances in AI and computer vision in industrial inspection*. Berlin, Germany: Springer-Verlag.
- LaBellerr. (2023). *Transforming industrial maintenance with computer vision*. Obtenido de LaBellerr: <https://www.labellerr.com/blog/transforming-industrial-maintenance-the-power-of-computer-vision/>
- Labs, V. (2023). *Confusion Matrix: How To Use It & Interpret Result*. Obtenido de V7 Labs: <https://www.v7labs.com/blog/confusion-matrix-guide>
- learning, D. a. (2018). *Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning*. Obtenido de <https://arxiv.org/abs/1808.02518>
- Mundial, F. E. (2023). *The Future of Jobs Report 2023. World Economic Forum*. Obtenido de Foro Económico Mundial: <https://www.ioe-emp.org/index.php?eID=dumpFile&f=160483&t=f&token=b20f659739088aa974bdc3f78b5d8bf1fc5e67f1>
- Sanders, R. A. (2020). *Inspection methods for advanced industrial applications*. New York, NY: Springer.
- Smith, J. &. (2018). *Optimization techniques in weld inspection*. London, UK: Taylor & Francis.
- Tulip. (s.f.). *Automated Visual Inspection: How AI is changing quality control*. Obtenido de <https://tulip.co/es/blog/automated-visual-inspection>
- Vision, B. (s.f.). *Introducción a la visión artificial*. Obtenido de BCN Vision: https://bcnvision.es/uploads/videotutoriales/uploads/guias%20por%20sectores/introduccion%20a%20la%20vision%20artificial_compressed.pdf

ANEXOSAnexo 1: ENTRENAMIENTO DE UN MODELO CNN

```

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

# Parámetros
sizeVar = 150
batchSize = 32
numClasses = 5
epochs = 10
inputSize = 150

# Transformaciones para las imágenes
transform = transforms.Compose([
    transforms.Resize((sizeVar, sizeVar)),
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5]) #
Normalización
])

# Cargar los datos
def load_data(directory):
    dataset = datasets.ImageFolder(directory, transform=transform)
    dataloader = DataLoader(dataset, batch_size=batchSize, shuffle=True)
    return dataloader

trainData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenet
rantes/Dataset/AugmentedImages')
validationData =
load_data('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenet
rantes/Dataset/Images3')

# Definir el modelo convolucional
model = nn.Sequential(
    nn.Conv2d(3, 32, kernel_size=3), # Primera capa convolucional
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),

    nn.Conv2d(32, 64, kernel_size=3), # Segunda capa convolucional
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),

    nn.Conv2d(64, 128, kernel_size=3), # Tercera capa convolucional
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),

    nn.Flatten(), # Aplanar las dimensiones

```

```

)

# Calcular dinámicamente el tamaño de salida después de las capas
convolucionales
with torch.no_grad():
    exampleInput = torch.randn(1, 3, inputSize, inputSize) # Ejemplo de
    entrada
    outputSize = model(exampleInput).shape[1] # Número de características
    después de las capas convolucionales

# Ajustar el modelo con la capa totalmente conectada correcta
model = nn.Sequential(
    nn.Conv2d(3, 32, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(32, 64, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Conv2d(64, 128, kernel_size=3),
    nn.ReLU(),
    nn.MaxPool2d(kernel_size=2),
    nn.Flatten(),
    nn.Linear(outputSize, 128), # Capa totalmente conectada ajustada
    nn.ReLU(),
    nn.Linear(128, numClasses) # Capa de salida
)

# Configurar el optimizador y la pérdida
optimizer = optim.Adam(model.parameters(), lr=0.001)
criterion = nn.CrossEntropyLoss()

# Entrenamiento
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
model.to(device)

for epoch in range(epochs):
    model.train()
    runningLoss = 0.0
    for inputs, labels in trainData:
        inputs, labels = inputs.to(device), labels.to(device)
        optimizer.zero_grad()
        outputs = model(inputs)
        loss = criterion(outputs, labels)
        loss.backward()
        optimizer.step()
        runningLoss += loss.item()

    print(f"Epoch {epoch + 1}/{epochs}, Loss: {runningLoss /
len(trainData)}")

# Validación
model.eval()
valAccuracy = 0
with torch.no_grad():

```

```

    for inputs, labels in validationData:
        inputs, labels = inputs.to(device), labels.to(device)
        outputs = model(inputs)
        _, predictions = torch.max(outputs, 1)
        valAccuracy += (predictions == labels).sum().item()
    valAccuracy /= len(validationData.dataset)
    print(f"Validation Accuracy: {valAccuracy:.2f}")

# Guardar el modelo
torch.save(model.state_dict(),
"/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenetrantes/Dataset/Líquidos0.4.pth")

```

ANEXO 1 " Entrenamiento de un Modelo CNN para la Detección de Defectos en Soldaduras mediante Inspección con Líquidos Penetrantes"

(Fuente: Elaboración Propia)

Anexo 2: ANÁLISIS DE TIPOS DE DEFECTOS EN UNIONES SOLDADAS

```

import torch
import torch.nn as nn
import torchvision.transforms as transforms
from PIL import Image
import os
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

# Definir la arquitectura del modelo usando nn.Sequential
class OxideModel(nn.Module):
    def __init__(self, output_size, num_classes):
        super(OxideModel, self).__init__()
        self.model = nn.Sequential(
            nn.Conv2d(3, 32, kernel_size=3), # Convulsión de entrada
            nn.ReLU(),
            nn.MaxPool2d(kernel_size=2),
            nn.Conv2d(32, 64, kernel_size=3),
            nn.ReLU(),
            nn.MaxPool2d(kernel_size=2),
            nn.Conv2d(64, 128, kernel_size=3),
            nn.ReLU(),
            nn.MaxPool2d(kernel_size=2),
            nn.Flatten(), # Aplanar para pasar a la capa lineal
            nn.Linear(output_size, 128), # Ajustar según el tamaño de
            salida
            nn.ReLU(),
            nn.Linear(128, num_classes) # Salida con el número de clases
        )

    def forward(self, x):
        return self.model(x)

```

```

# Función para calcular el tamaño de la salida de las capas
convolucionales
def get_output_size(input_size):
    # Pasar por las capas convolucionales y de pooling para calcular el
    tamaño de salida
    x = torch.zeros(1, 3, input_size, input_size) # Una imagen de tamaño
input_size
    model = nn.Sequential(
        nn.Conv2d(3, 32, kernel_size=3),
        nn.ReLU(),
        nn.MaxPool2d(kernel_size=2),
        nn.Conv2d(32, 64, kernel_size=3),
        nn.ReLU(),
        nn.MaxPool2d(kernel_size=2),
        nn.Conv2d(64, 128, kernel_size=3),
        nn.ReLU(),
        nn.MaxPool2d(kernel_size=2),
        nn.Flatten()
    )
    output = model(x)
    return output.view(1, -1).size(1)

# Tamaño de las imágenes
input_size = 150
output_size = get_output_size(input_size) # Calcular el tamaño de salida
después de las convoluciones
num_classes = 5 # Número de clases

# Inicializar el modelo

model = OxideModel(output_size, num_classes)
checkpoint =
torch.load('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPene
trantes/Dataset/Líquidos0.4.pth')
new_state_dict = {}
for key, value in checkpoint.items():
    # Renombrar las claves de "0" a "model.0", "3" a "model.3", etc.
    new_key = f"model.{key}"
    new_state_dict[new_key] = value

model.load_state_dict(new_state_dict)
# model.load_state_dict(torch.load('./oxide_model.pth')) # Cargar los
pesos en el modelo
model.eval() # Poner el modelo en modo de evaluación

# Definir las transformaciones
transform = transforms.Compose([
    transforms.Resize((input_size, input_size)), # Redimensionar la
imagen
    transforms.ToTensor(), # Convertir la imagen a tensor
    transforms.Normalize(mean=[0.5, 0.5, 0.5], std=[0.5, 0.5, 0.5]) #
Normalización
])

```

```

# Función para predecir el tipo de óxido para una imagen
def predict_image(img_path, model):
    img = Image.open(img_path).convert('RGB') # Convertir a RGB si es
necesario
    img = transform(img).unsqueeze(0) # Aplicar las transformaciones y
agregar dimensión de batch
    output = model(img) # Pasar la imagen al modelo
    _, predicted = torch.max(output, 1)
    return predicted

# Función para calcular los porcentajes de tipos por carpeta
def calculate_percentages(directory, model, class_names):
    matriz = []
    for folder_name in sorted(os.listdir(directory)):
        folder_path = os.path.join(directory, folder_name)
        if os.path.isdir(folder_path):
            # Contadores de cada clase
            class_counts = {class_name: 0 for class_name in class_names}
            total_images = 0

            # Recorrer todas las imágenes en la carpeta
            for img_name in sorted(os.listdir(folder_path)):
                img_path = os.path.join(folder_path, img_name)
                if img_path.lower().endswith(('.png', '.jpg',
'.jpeg')): # Filtrar solo imágenes
                    predicted_class = predict_image(img_path, model)
                    class_counts[class_names[predicted_class]] += 1
                    total_images += 1

                    # print(f'Imagen {img_name} pertenece a: Tipo {1 +
predicted_class}')

            # Calcular y mostrar los porcentajes
            print(f"Porcentaje de tipos en la carpeta {folder_name}:")
            lista = []
            for class_name in class_names:
                percentage = (class_counts[class_name] / total_images) *
100 if total_images > 0 else 0
                print(f" {class_name}: {percentage:.2f}%")
                lista.append(percentage)
            matriz.append(lista)
            print('\n\n')
    return matriz

# Nombres de las clases (tipo de óxido)
class_names = ['Tipo1', 'Tipo2', 'Tipo3', 'Tipo4', 'Tipo5']

# Directorio donde están las imágenes a analizar (Images2)
directory =
'/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenetrantes/Dat
aset/Images3'

# Calcular y mostrar los porcentajes por carpeta
matriz = calculate_percentages(directory, model, class_names)

```

```

for i in matriz:
    print(i)
matrix = np.array(matriz)
# Etiquetas
labelsx = ['Tipo1', 'Tipo2', 'Tipo3', 'Tipo4', 'Tipo5']
labelsy = ['Carpeta 1', 'Carpeta 2', 'Carpeta 3', 'Carpeta 4', 'Carpeta 5']

# Crear el gráfico
plt.figure(figsize=(6, 5))
sns.heatmap(matrix, annot=True, fmt='.2f', cmap='Blues',
xticklabels=labelsx, yticklabels=labelsy, cbar=True)

# Título y etiquetas
plt.title('Matriz de Confusion')
plt.xlabel('Tipos')
plt.ylabel('Carpetas')

# Guardar la imagen como un archivo PNG
plt.savefig('/content/gdrive/MyDrive/IA.LiquidosPenetrantes/IA.LiquidosPenetrantes/Dataset/Matriz de Confusion.png', format='png')

# Mostrar la imagen
plt.show()

```

ANEXO 2 " Análisis de Tipos de Defectos en Uniones Soldadas Usando Redes Neuronales Convolucionales"

(Fuente: Elaboración Propia)

Anexo 3: OPTIMIZACIÓN DE UN MODELO DE VISIÓN COMPUTACIONAL

```

import matplotlib.pyplot as plt

# Inicializar listas para guardar las métricas
train_losses = []
val_accuracies = []

# Definir optimizador y función de pérdida
optimizer = torch.optim.Adam(model.parameters(), lr=0.001)
criterion = nn.CrossEntropyLoss()

# Entrenamiento
device = torch.device("cuda" if torch.cuda.is_available() else "cpu")
model.to(device)

epochs = 10 # Reduce las épocas para pruebas rápidas

for epoch in range(epochs):
    # Modo entrenamiento
    model.train()
    running_loss = 0.0
    for inputs, labels in trainData:
        inputs, labels = inputs.to(device), labels.to(device)

```

```

optimizer.zero_grad()
outputs = model(inputs)
loss = criterion(outputs, labels)
loss.backward()
optimizer.step()
running_loss += loss.item()

# Guardar pérdida promedio por época
train_losses.append(running_loss / len(trainData))
print(f"Epoch {epoch + 1}/{epochs}, Loss: {train_losses[-1]:.4f}")

# Validación
model.eval()
correct_predictions = 0
total_samples = 0
with torch.no_grad():
    for inputs, labels in validationData:
        inputs, labels = inputs.to(device), labels.to(device)
        outputs = model(inputs)
        _, predictions = torch.max(outputs, 1)
        correct_predictions += (predictions == labels).sum().item()
        total_samples += labels.size(0)
val_accuracy = correct_predictions / total_samples
val_accuracies.append(val_accuracy)
print(f"Validation Accuracy: {val_accuracy:.4f}")

# Graficar pérdida de entrenamiento
plt.figure(figsize=(10, 5))
plt.plot(range(1, epochs + 1), train_losses, label='Train Loss')
plt.xlabel('Epochs')
plt.ylabel('Loss')
plt.title('Training Loss Over Epochs')
plt.legend()
plt.grid()
plt.show()

# Graficar exactitud de validación
plt.figure(figsize=(10, 5))
plt.plot(range(1, epochs + 1), val_accuracies, label='Validation Accuracy')
plt.xlabel('Epochs')
plt.ylabel('Accuracy')
plt.title('Validation Accuracy Over Epochs')
plt.legend()
plt.grid()
plt.show()

```