

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
CAMPUS SAN JUAN DEL RÍO
FACULTAD DE INGENIERÍA
MAESTRÍA EN CIENCIAS -MECATRÓNICA

“DESARROLLO DE UNA RED NEURONAL CONVOLUCIONAL
(WELDINGNET) PARA LA CLASIFICACIÓN DE CALIGRAFÍAS DE
SOLDADURA TIPO MIG”

PRESENTA:
ING. OSIRIS GIUSEPPE GARCÍA ZARATE

DIRIGIDO POR:
DR. JOSÉ LUIS GONZÁLEZ CÓRDOBA

CODIRIGIDO POR:
DR. MARTÍN VALTIERRA RODRÍGUEZ

SAN JUAN DEL RÍO, QUERÉTARO, 2025

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciatario no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:

 **Atribución** — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciatario.

 **NoComercial** — Usted no puede hacer uso del material con [propósitos comerciales](#).

 **SinDerivadas** — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.

Universidad Autónoma de Querétaro

Facultad de Ingeniería

Desarrollo de una red neuronal convolucional (WeldingNet) para la clasificación de caligrafías de soldadura tipo MIG

Tesis

Que como parte de los requisitos para obtener el título de maestro en ciencias (mecatrónica)

Presenta:

Ing. Osiris Giuseppe García Zarate

Dirigido por:

Dr. José Luis González Córdoba

Codirigido por:

Dr. Martín Valtierra Rodríguez

Dr. José Luis González Córdoba

Presidente

_____ Firma

Dr. Martín Valtierra Rodríguez

Secretario

_____ Firma

Dr. Juan Primo Benítez Rangel

Vocal

_____ Firma

Dr. J. Jesús de Santiago Pérez

Sinodal

_____ Firma

Dr. Jesús Rooney Rivera Guillén

Sinodal

_____ Firma

Campus San Juan del Río, Qro.

México

RESUMEN

El presente trabajo propone una metodología para la clasificación automática de caligrafías en cordones de soldadura tipo MIG-FCAW mediante el uso de visión por computadora y redes neuronales convolucionales. A través del diseño e implementación de la red neuronal Convolutional WeldingNet, se desarrolló un sistema capaz de identificar patrones geométricos característicos (zigzag, lineal, circular y cuadrado), manufacturados en una celda de soldadura robótica. La propuesta busca atender las necesidades tanto de la industria como de talleres de bajo presupuesto y laboratorios escolares, eliminando la dependencia de sensores especializados o sistemas de retroalimentación costosos.

La metodología abarca desde la fabricación de cordones de prueba y adquisición de imágenes hasta su preprocesamiento, clasificación y validación automatizada. El preprocesamiento incluyó conversión a escala de grises, ecualización de histograma y redimensionamiento a 140x224 píxeles. Posteriormente, se entrenó la red WeldingNet utilizando un conjunto balanceado de 708 imágenes (177 por cada clase de caligrafía), con una distribución del 60% para entrenamiento, 20% para validación y 20% para prueba. La red alcanzó una precisión superior al 95% en el conjunto de validación, manteniéndose estable a lo largo de 30 épocas, lo cual indica una buena capacidad de generalización sin sobreajuste.

Además, se desarrolló una interfaz gráfica intuitiva en MATLAB que permite al usuario seleccionar imágenes individuales o carpetas completas para su clasificación, facilitando el uso práctico del sistema en escenarios reales de producción o entrenamiento. Aunque el presente trabajo se enfoca en la clasificación de la geometría del cordón, la estructura planteada permite su futura ampliación hacia la estimación de parámetros del proceso, como voltaje, corriente o velocidad de alimentación, a partir de las características visuales capturadas.

Palabras clave: *Caligrafía de soldadura, Redes Neuronales Convolucionales, Soldadura tipo MIG-FCAW.*

DEDICATORIA

A mi mamá, que, a pesar de todas las peripecias, siempre estuvo y está, apoyando y esperando lo mejor.

AGRADECIMIENTOS

A mis padres, por los cuales estoy aquí, y me dieron suficientes motivos

A mis hermanos, por el apoyo que me dan

A todos mis profesores, por todo su conocimiento

A mis compañeros, por estar a mi lado aportando ayuda.

A mis amigos, sin los cuales, no sería lo que soy.

ÍNDICE

RESUMEN.....	3
DEDICATORIA	4
AGRADECIMIENTOS	5
ÍNDICE DE FIGURAS.....	10
ÍNDICE DE TABLAS	11
Capítulo 1. Introducción.....	13
1.1 Antecedentes	15
1.2 Descripción del problema	20
1.3 Justificación	22
1.4 Hipótesis y objetivos	23
1.4.1 Hipótesis.....	23
1.4.2 Objetivo general.....	24
1.4.3 Objetivos particulares	24
1.5 Planteamiento general.....	24
1.5.1 Revisión del estado del arte.....	25
1.5.2 Manufactura de piezas muestra	25
1.5.3 Construcción de base de datos	25
1.5.4 Diseño y desarrollo de la arquitectura de la red CNN.....	26
1.5.5 Desarrollo y pruebas de software	27
1.5.6 Redacción de tesis.....	28
Capítulo 2 Fundamentación teórica y tecnológica	29
2.1 Soldadura MIG-FCAW.....	30
2.1.1 Bases teóricas soldadura MIG.....	30
2.1.2 Movimientos de electrodo (caligrafías)	32
2.1.3 Posiciones de soldadura y selección de caligrafías.	33
2.2 Pruebas no destructivas (NDT).....	36
2.2.1 Inspección visual	36
2.2.2 Radiografía	36
2.2.3 Ultrasonido.....	36
2.2.4 Partículas magnéticas.....	37
2.2.5 Líquidos penetrantes.....	37
2.3 Cámaras – sensores de obtención de imágenes	37

2.4 Visión artificial	38
2.4.1 Representación matricial	40
2.4.2 Escala de grises.....	40
2.4.3 Imagen negativa	41
2.4.4 Filtrado de imágenes y convolución discreta.....	42
2.4.4.1 Filtro promedio	42
2.4.4.2 Filtro gaussiano	43
2.4.5 Umbralización	44
2.4.6 Binarización	45
2.4.7 Ecualización de contraste.....	46
2.4.8 Procesamiento morfológico	47
2.4.8.1 Erosión.....	47
2.4.8.2 Dilatación	48
2.4.9 Región de interés (ROI)	49
2.5 Redes neuronales artificiales	49
2.5.1 Fundamentos de redes neuronales artificiales	49
2.5.2 Fundamentos de redes neuronales artificiales.....	50
2.5.3 Arquitecturas comunes en aprendizaje profundo	52
2.5.3.1 Redes neuronales profundas (deep feedforward neural networks, D-FFNN)	52
2.5.3.2 Redes neuronales convolucionales (convolutional neural networks, CNN)	52
2.5.3.3 Redes neuronales recurrentes (recurrent neural networks, RNN) y LSTM	53
2.5.3.4 Autoencoders (AE)	53
2.5.3.5 Redes de creencia profunda (deep belief networks, DBN)	53
2.5.4 Redes neuronales convolucionales (CNN)	54
2.5.5 Métricas de desempeño.....	56
2.5.5.1 Exactitud global (accuracy)	56
2.5.5.2 Precisión por clase (precision)	57
2.5.5.3 Sensibilidad (recall)	58
2.5.5.4 F1-score	59
2.5.5.5 Matriz de confusión	59
2.6 Software para desarrollo.....	60
2.6.1 Phyton	60
2.6.2 RobotStudio.....	61

2.6.3 Matlab	62
Capítulo 3 Metodología.....	63
3.1 Fabricación de cordones de soldadura	64
3.1.1.1 Reconocimiento del equipo.	65
3.1.1.2 Sugerencia de herramiental.....	67
3.1.2 Programación de trayectorias.....	69
3.1.2.1 Trayectoria cuadrada	70
3.1.2.2 Trayectoria zigzag.....	70
3.1.2.3 Trayectoria semicircular (medialuna)	70
3.1.2.3 Trayectoria circular	71
3.1.3 Preparación de equipo y mesa.....	71
3.1.4 Etiquetado.....	73
3.1.4.1 Medición velocidad micro alambre.....	75
3.1.5 Matriz de pruebas	76
3.2 Adquisición de imágenes.....	77
3.3 Preprocesamiento de imágenes.....	79
3.4 Propuesta de arquitectura de CNN y entrenamiento	80
3.4.1 Preparación de los datos de entrada	81
3.4.2 Arquitectura base propuesta	82
3.4.2.1 Capa de entrada (input layer):	82
3.4.2.2 Bloques de convolución y pooling:.....	82
3.4.2.3 Capa de aplanamiento (flatten layer):	82
3.4.2.4 Capa densa oculta (hidden dense layer):	82
3.4.2.5 Capa de regularización (dropout):	82
3.4.2.6 Capa de salida (output layer):	83
3.5 Validación.....	83
3.6 Desarrollo de software	83
Capítulo 4 Experimentación y Resultados	86
4.1 Configuración experimental.....	87
4.1.1 Equipamiento utilizado	87
4.1.2 Programación y ejecución de trayectorias robóticas.....	87
4.1.2.1 Programación de trayectoria cuadrada	88
4.1.2.2 Programación de trayectoria zigzag.....	90

4.1.2.3 Programación de trayectoria semicircular	91
4.1.2.4 Programación de trayectoria circular.....	92
4.1.3 Herramental sugerido y condiciones operativas reales.....	93
4.2 Materiales y condiciones de prueba	95
4.2.1 Tablas de voltaje y obtención según parámetros establecidos	95
4.2.2 Medición de velocidad y cantidad de micro alambre	97
4.3 Matriz de prueba por caligrafía.....	98
4.3.1 Matriz de prueba de caligrafía zigzag.....	99
4.3.2 Matriz de prueba de caligrafía medialuna	100
4.3.3 Matriz de prueba de caligrafía cuadrada	101
4.3.4 Matriz de prueba de caligrafía circular	102
4.4.1 Procesamientos utilizados.....	104
4.4.1.1 Redimensionamiento:	105
4.4.1.2 Conversión a escala de grises:.....	105
4.4.1.3 Ecualización de histograma:.....	105
4.4.1.4 Verificación visual posprocesamiento:	105
4.4.2 Base de datos generada y acomodo en carpetas según código	106
4.5 Implementación de la red neuronal convolucional (CNN).....	107
4.5.1 Arquitectura seleccionada	107
4.5.2 Entrenamiento del modelo	109
4.6 Validación del modelo.....	111
4.7 Desarrollo e implementación del software de validación.....	114
4.7.1 Descripción de la interfaz (layout)	114
4.7.2 Pantallas (vistas de uso de la interfaz)	116
4.7.2.1 Pantalla inicial	116
4.7.2.2 Selección de caligrafía objetivo	116
4.7.2.3 Análisis de archivo individual	117
4.7.2.4 Análisis de carpeta	119
4.7.2.5 Clasificación incorrecta respecto al objetivo	120
.....	120
4.7.2.5 Guardado del informe	120
Capítulo 5 Conclusiones y Prospectivas	122
5.1 Conclusiones.....	123

5.2 Prospectivas	124
Bibliografía	127
Anexos.....	132
Constancia presentación ICAPPLEC	132
Artículo	132

ÍNDICE DE FIGURAS

Figura 1 Enfoques usuales de clasificación de defectos de soldadura (Hairol Nizam et al. 2016) ...	17
Figura 2 Planteamiento general del presente proyecto.....	24
Figura 3 Diagrama esquemático de sistema de soldadura tipo MIG (adaptada de Weman, K., & Lindén, G., 2006).	31
Figura 4 Ejemplo de caligrafías de soldadura.	33
Figura 5 Ejemplos de usos de caligrafías de soldadura tomados de curso de capacitación en soldadura (2. ^a ed.) de Gaxiola Maya, editorial LIMUSA. [Págs. 92–151].....	34
Figura 6 Ejemplos de caligrafías de soldador.	35
Figura 7 Cámara RGB comercial Canon Rebel T8i.....	37
Figura 8 Ejemplo de aplicación de filtro promedio.....	43
Figura 9 Ejemplo de aplicación de filtro gaussiano.	44
Figura 10 Ejemplo de umbralización a 2 niveles diferentes (64 y 128).	45
Figura 11 Ejemplo de binarización a 2 niveles diferentes (10 y 128).	46
Figura 12 Ejemplo de ecualización de contraste	47
Figura 13 Ejemplo de binarización y erosión.....	48
Figura 14 Ejemplo de erosión y dilatación.....	48
Figura 15 Diagrama general de red neuronal convolucional CNN adaptada de Matlab (2024)	54
Figura 16 Diagrama explicativo de precisión y exactitud.	58
Figura 17 Explicación matriz de confusión.....	59
Figura 18 Imagen ejemplo RobotStudio adaptada de abb.com (2024)	61
Figura 19 Metodología general planteada	64
Figura 20 Metodología seguida para fabricación de cordones	65
Figura 21 Robot ABB IRB 1410 y controlador ABB IRC5 M2004	65
Figura 22 Máquina VOL-MIG110.....	66
Figura 23 Herramental usual para soldadura robótica.....	67
Figura 24 Plantilla de proceso, antes y después de uso (WeldingNet).....	68
Figura 25 Recomendación de distancia de boquilla tomados de curso de capacitación en soldadura (2. ^a ed.) de Gaxiola Maya, editorial LIMUSA. [Pág. 142].....	72
Figura 26 Medición de voltaje en vacío	73
Figura 27 Sistema de alimentado de micro alambre de maquina VOL-MIG110.....	76
Figura 28 Representación gráfica de la estructura de la matriz de pruebas de soldadura	77
Figura 29 Diagrama explicativo captura de imágenes.	78
Figura 30 Ejemplo de procesamientos a) original b) conversión a gris c) detección de contornos d) negativo e) ecualización de histograma.....	79

Figura 31 Layout Interfaz WeldingNet	84
Figura 32 Ejemplo ejecución rutina robot ABB.....	88
Figura 33 Herramental utilizado en TCP	94
Figura 34 Distancia recomendada y consecuencia de no seguirla	95
Figura 35 Matriz de pruebas para caligrafía zigzag	100
Figura 36 Matriz de pruebas para caligrafía medialuna.....	101
Figura 37 Matriz de pruebas para caligrafía cuadrada	102
Figura 38 Matriz de pruebas para caligrafía circular	103
Figura 39 Toma de fotografías 3 ángulos, para 4 caligrafías (a. circular b. cuadrada c. media luna d. zigzag	104
Figura 40 Procesamiento aplicado a) Redimensionamiento (100x160).....	105
Figura 41 Imagen ates y después de redimensionamiento	106
Figura 42 Estructura de carpetas de base de datos WeldingNet.....	106
Figura 43 Arquitectura WeldingNet.....	107
Figura 44 Ejemplo de las primeras 3 convoluciones a una imagen de caligrafía cuadrada	108
Figura 45 Grafica de vector aplanado	109
Figura 46 Grafica de capas densas totalmente conectadas y capas de salida (softmax)	109
Figura 47 Graficas de entrenamiento de WeldingNet.....	111
Figura 48 Matriz de confusión para caligrafías de soldadura.....	112
Figura 49 Matriz de confusión para caligrafías de soldadura.....	114
Figura 50 Pantalla inicial (WeldingNet).	116
Figura 51 Menú desplegable para seleccionar la caligrafía (WeldingNet).	117
Figura 52 Selección de caligrafía objetivo (WeldingNet).	117
Figura 53 Selección de archivo individual (WeldingNet).	118
Figura 54 Análisis individual (WeldingNet).	118
Figura 55 Selección de carpeta (WeldingNet).	119
Figura 56 Análisis de carpeta, coincidente (WeldingNet).	119
Figura 57 Análisis de carpeta, no coincidente (WeldingNet).....	120
Figura 58 Guardado de reporte (WeldingNet).	121

ÍNDICE DE TABLAS

Tabla 1 Pseudocódigo trayectoria cuadrada.....	89
Tabla 2 Pseudocódigo trayectoria zigzag.....	90
Tabla 3 Pseudocódigo trayectoria semicircular (medialuna)	91
Tabla 4 Pseudocódigo trayectoria circular	93
Tabla 5 Valores estimados de voltaje y corriente según niveles del equipo VOL-MIG110	97
Tabla 6 Velocidad de alimentación y porcentaje de uso del rollo de micro alambre.....	98
Tabla 7 Parámetros de entrenamiento WeldingNet.....	110
Tabla 8 Métricas por clase.	113
Tabla 9 Métricas globales.	113
Tabla 10 Resumen Interfaz Gráfica.	115

Capítulo 1.

Introducción

La soldadura es un método de unión rápida de metales a través de la fusión de estos, en la cual se calientan 2 piezas metálicas por encima de su punto de fusión, permitiendo que sus porciones fundidas se mezclen y creando así una coalescencia. Durante este proceso se produce una mezcla intergranular de los dos metales, que al enfriarse y solidificarse resultan en una unión firme y resistente (Sen et al., 2018). En el caso de la Soldadura tipo MIG/MAG (Gas Inerte Metálico, del inglés Metal Inert Gas y soldadura con gas activo metálico, del inglés Metal Active Gas) es el arco eléctrico el que produce el calor necesario para fundir el alambre del electrodo y los componentes metálicos a soldar (Pires et al., 2003). Particularmente en su variante con alambre tubular autoprotegido o Flux-Cored Arc Welding (FCAW), la cual se distingue porque no requiere un suministro externo de gas protector, al estar incluido en el fundente del material, simplificando la operación especialmente en condiciones adversas y ampliando así su rango de aplicaciones industriales (Kah, Suoranta & Martikainen, 2012).

Se puede decir que la soldadura es una tecnología que proporciona el método más rápido, más fuerte y económico para unir metales (Hong et al., 2014). Según la American Welding Society (AWS), aproximadamente entre el 50% y 60% de la soldadura en la industria metalmecánica corresponde al proceso MIG, cifra que incrementa hasta un 70% cuando se refiere específicamente a aplicaciones robotizadas en el sector automotriz (Jeffus, 2011; IFR, 2012). Como todo proceso de manufactura, el proceso de soldadura es afectado por el entorno de producción y el proceso de fabricación, donde inevitablemente ocurren diversos defectos de soldadura como poros, grietas, falta de fusión, pulverización catódica y socavados (Ji et al., 2019).

Para evitar dichos defectos los soldadores experimentados suelen ajustar los parámetros necesarios de forma adaptativa a las condiciones y circunstancias específicas, debido a que la operación y control del proceso MIG presenta una considerable complejidad debido a las numerosas variables involucradas, tales como el voltaje, corriente, velocidad de alimentación del alambre, velocidad de avance y patrones específicos de movimiento del electrodo o antorcha denominados caligrafías (Pires et al., 2003; Hong et al., 2014). Generalmente, estos patrones son seleccionados por soldadores experimentados, quienes realizan ajustes y preparación, pero actualmente la industria enfrenta una notable escasez global de personal calificado para estas tareas, además de la creciente demanda por una repetibilidad y precisión

que difícilmente pueden garantizarse con operaciones manuales (Dalloz et al., 2017; Popović, 2014). En respuesta a estos desafíos, la implementación de sistemas robóticos en la soldadura se ha convertido en una solución, principalmente por su capacidad para asegurar la repetibilidad en el proceso productivo (Pires et al., 2003; Ghobakhloo & Khaksar, 2014).

1.1 Antecedentes

El proceso de soldadura es por sí mismo complejo con un gran número de variables a considerar, difícil de parametrizar, de monitorear y controlar de manera efectiva (Wang et al., 2020). De hecho, no se comprenden los efectos sobre las uniones de la mayoría de las técnicas de soldadura, y los sistemas normalmente se regulan y utilizan basándose en modelos empíricos obtenidos por experiencia del operador (Pires et al., 2003).

Para mejorar la habilidad de los soldadores en desarrollo se apoyan en ejercicios donde se practican movimientos específicos que posteriormente se usarán para formar un cordón de soldadura firme y homogéneo basándose en movimientos predefinidos muy similares a los ejercicios utilizados en escritura para mejorar de caligrafía. Dichos ejercicios sirven para ejercitar la habilidad del soldador y su capacidad de seguir patrones por medio de memoria muscular y ejecutar dichos movimientos aun con las difíciles condiciones visión al momento de soldar. Sin embargo, es importante acelerar la transición de la soldadura manual a la soldadura automática (Popović O 2014). La productividad de los soldadores humanos no puede satisfacer la demanda cada vez mayor de eficiencia de fabricación (Wang et al., 2020) además que, a nivel mundial, se enfrenta una gran escasez de soldadores capacitados (Dalloz et al., 2017); de hecho, también es necesario considerar la salud de los soldadores humanos que se ve perjudicada debido a la exposición a humos y gases tóxicos inherentes al campo de soldadura (Popović O 2014).

Para llevar a cabo esta transición es necesario entender el fenómeno de estudio. En la literatura, diversos trabajos recientes se han enfocado en la implementación de técnicas avanzadas para automatizar y mejorar la calidad de los procesos de soldadura, empleando métodos de aprendizaje automático e inteligencia artificial debido a su capacidad para manejar múltiples variables simultáneamente y detectar patrones complejos. En dichos estudios se ha investigado el efecto de variables en los procesos que involucran parámetros como profundidad de penetración, corriente, voltaje, velocidad de suministro de material,

velocidad de avance, así como parámetros como largo, ancho y tipo de cordón, según la aplicación, además de estándares de calidad y apariencia de la soldadura (por ejemplo, defectos que incluyen deformación, distorsión y agrietamiento), propiedades mecánicas y comportamiento (por ejemplo, transformaciones de fase) y desgaste de herramientas (Wang et al., 2020).

Estas condiciones, entre otras fueron estudiadas por Sen, R. (2018) donde pudo concluir que afectan directamente a factores críticos como el tamaño, la forma y la penetración del cordón, así como la calidad final, los costos y la productividad del trabajo de soldadura. También se reconoce que una superficie de cordón uniforme es fundamental para mejorar la respuesta del material a la tensión de fatiga y para optimizar la microestructura y otras propiedades relacionadas y así evitar condiciones donde la fatiga cerca de la soldadura ocasione grietas y tensión mecánica elevada alrededor de la zona afectada por el calor HAZ (del inglés, heat affected zone).

Debido a la naturaleza estructural, es más común usar ensayos no destructivos (NDT, del inglés Non-Destructive Testing), aun cuando la principal desventaja de los sistemas de medición sin contacto es su alta sensibilidad a diversos factores ambientales externos inherentes al proceso de medición o a las características ópticas del objeto (Ramos B. et al., 2011). A pesar de los diferentes métodos de inspección de calidad de soldadura, muchos están enfocados en el seguimiento de parámetros de máquina durante la ejecución (generalmente asistida por robot); sin embargo, la inspección visual es la que más se ha utilizado para detección de defectos, abstrayendo las características del cordón de soldadura.

Las señales de visión capturadas por cámaras con Dispositivo de carga Acoplada (CCD del inglés Charge-Coupled Device) o de rayos X pueden proporcionar adecuadamente imágenes útiles para la distinción de formas y posiciones, y contener datos de intensidad de color o escala de grises. Se tienen diferentes retos como superficies sin textura, condiciones de iluminación que pueden provocar brillos, occlusiones por el punto de vista de la cámara, objetos en movimiento indeterminados o el ruido inherente durante el proceso de soldadura, normalmente el generado por el arco, hollín o salpicaduras que pueden modificar las trayectorias del sensor CCD.

Por lo que antes de proceder al procesamiento de imágenes, es necesario seleccionar imágenes útiles ya que el proceso de adquisición se ve muy afectado por salpicaduras, transferencia de gotas, humo y ruidos asociados (Rout A et al., 2019). Un ejemplo de esto se puede apreciar con Shevchik et al. (2021) que utilizaron radiografías de rayos X duros para obtener imágenes de soldadura láser donde se usaron diferentes de modelos CNN para clasificar defectos en imágenes de rayos X, resultando en una confianza de la clasificación de defectos oscila entre el 71% y el 99%, y el tiempo de cálculo por tarea de clasificación de 2 ms.

Dentro de las posibles formas de abordar la inspección de cordones de soldadura, se encuentra el trabajo de Hairol Nizam et al. (2016), el cual presentó un estudio de la forma que se aborda la detección de soldadura, aunque como la mayoría de los estudios realizados son para aplicaciones específicas, donde los cordones dependen de la naturaleza propia de la geometría y tipo de materiales que se requiere, dentro de su estudio pudieron considerar los enfoques comunes de detección de defectos de soldadura como se muestra en la figura 1.

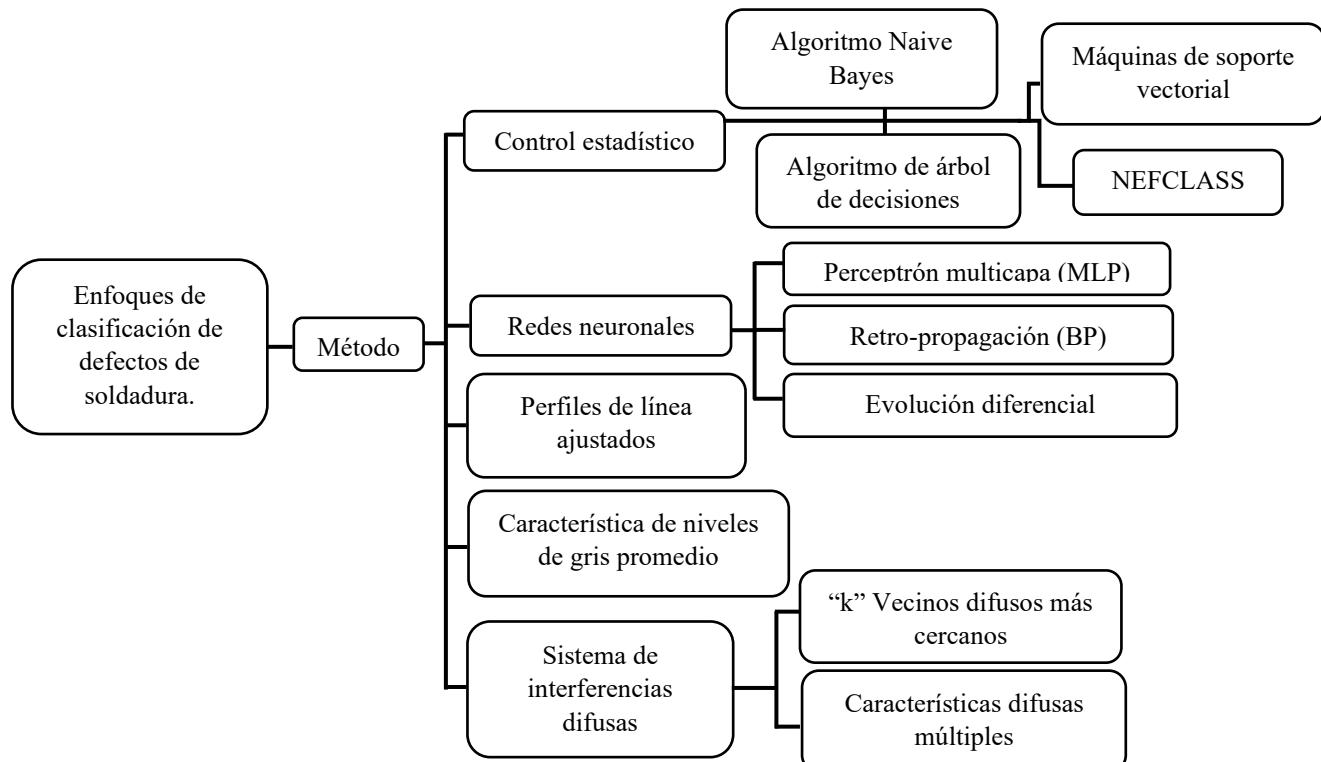


Figura 1 Enfoques usuales de clasificación de defectos de soldadura (Hairol Nizam et al. 2016)

Mientras que para casos con soldaduras repetitivas y específicas conocidas, se opta por un seguimiento del cordón bajo condiciones controladas, para la clasificación y reconocimiento enfocado a defectos de soldadura, se ha optado por el uso de inteligencia artificial. En este aspecto se considera que la introducción de las redes neuronales convolucionales profundas (CNN) ha marcado un cambio significativo en el enfoque de la clasificación de imágenes. Estas redes tienen la capacidad de capturar características de distintos niveles y clasificadores en múltiples capas, generando así representaciones más precisas para tareas de reconocimiento visual (He., et al., 2016).

Además, las CNNs aprovechan propiedades estadísticas fundamentales de los datos de imágenes, sonidos y video, como la estacionariedad local y la estructura compositiva multinivel, lo que les permite capturar interacciones a diferentes escalas espaciales y temporales. Aunque estas características han demostrado su eficacia en una variedad de aplicaciones, es importante reconocer que su aplicabilidad puede ser limitada en otros tipos de datos, como documentos de texto o datos bioinformáticos, que podrían carecer de estas regularidades estadísticas (Henaff, 2015).

Por otro lado, en el reconocimiento de objetos se ha identificado un desafío significativo, donde los métodos tradicionales a menudo fallan al capturar información contextual crucial. Para abordar esta limitación, se han propuesto modelos más avanzados, como las redes neuronales convolucionales recurrentes (RCNN), que combinan elementos de convolución y recurrencia para capturar tanto la información espacial como temporal (Lai, et al., 2015). Además, se reconoce la necesidad de desarrollar modelos aún más sofisticados que puedan capturar relaciones temporales o espaciales complejas, como las redes neuronales recurrentes (Lipton, et al., 2015).

El papel crítico del aprendizaje automático en el reconocimiento de objetos es innegable, especialmente considerando cómo el acceso a conjuntos de datos más grandes ha impulsado mejoras significativas en el rendimiento de los modelos (Krizhevsky, 2012). Esta disponibilidad mejorada de datos etiquetados ha permitido a los investigadores abordar la variabilidad de los objetos en entornos realistas y mejorar la precisión del reconocimiento de objetos.

En la literatura reciente sobre clasificación de soldaduras mediante inteligencia artificial, destacan los estudios de Nguyen et al. (2016), quienes utilizaron transformadas de onda (wavelets) para identificar irregularidades con una precisión del 89%; así mismo Kim et al. (2018), que aplicaron Máquinas de Soporte Vectorial (SVM), logrando un 91% de precisión; y Zhao et al. (2019), quienes combinaron transformadas de Fourier con aprendizaje profundo obteniendo una precisión del 92% en clasificación automática de defectos. Asimismo, en línea de métodos basados en redes neuronales, Yang et al. (2021) aplicaron redes neuronales convolucionales (CNN) en soldaduras tipo TIG (Tungsten Inert Gas), logrando una precisión del 95.4%, mientras que Shevchik et al. (2021) utilizaron CNN sobre imágenes obtenidas mediante radiografías de rayos X en soldadura láser, con un rango de confianza entre 71% y 99%.

Sin embargo, a pesar de su eficacia, las redes neuronales estándar presentan limitaciones notables, especialmente en situaciones donde los puntos de datos están relacionados en el tiempo o el espacio. Esta suposición de independencia entre los ejemplos de entrenamiento y prueba puede ser problemática en escenarios como fotogramas de video, fragmentos de audio o palabras extraídas de oraciones, donde la correlación entre los datos es evidente (Lipton, et al., 2015). Una forma de atacar dicha problemática se puede ver con Choi et al. (2020) implementaron Redes Neuronales Recurrentes (RNN) para la detección en tiempo real mediante imágenes térmicas, alcanzando una precisión del 93%.

No obstante, estos trabajos se enfocaron principalmente en detección y clasificación de defectos específicos, sin contemplar la clasificación de caligrafías de soldadura ni su aplicabilidad directa en procesos MIG con alambre tubular autoprotegido (FCAW). Los estudios han sido limitados ya que no se ha contado con una base de datos amplia que pueda incluir diferentes tipos de soldadura o, más aún, que pueda evaluar la caligrafía en términos de calidad y eficiencia (Sen, et al., 2018). Aunado a esto, también se han desarrollado diversas técnicas y tecnologías para mejorar la calidad y eficiencia de los procesos de soldadura, como el uso de sistemas robotizados y automatizados, desarrollo de sistemas de monitorización en tiempo real que utilizan sensores y técnicas de procesamiento de señales, desarrollo de soldadura MIG pulsada y uso de nuevos materiales de soldadura y consumibles, así como aleaciones y gases de protección mejorados (Sen, et al., 2018). Aunque lo anterior

pareciera haber provisto la solución ideal al mundo de la manufactura y, particularmente, la soldadura, la realidad es que eso se puede observar en las industrias más sofisticadas que pueden costear dichos sistemas. Por lo tanto, aún queda el sector que no puede costear estos sistemas tecnológicos y requiere de herramientas asequibles que les permitan, regular, automatizar y mejorar su calidad de soldadura.

De forma local, en la Universidad Autónoma de Querétaro, se ha revisado su repositorio institucional y se ha encontrado un limitado número de trabajos relacionados o referentes al análisis de soldadura. De hecho, el más relevante es el presentado por Diana Flores et al (2023), en el cual se analizó la forma de reducir los defectos de soldadura específicamente en desprendimiento para piezas de la industria automotriz, mediante análisis estadístico a través de la parametrización del proceso y diseño de experimento controlado para la validación con pruebas de tensión máxima. Sin embargo, al igual que en la literatura disponible, se basa en casos específicos con punto de enfoque en la reducción de defectos mediante modificación o control de proceso. Por lo tanto, al momento no hay un antecedente de clasificación de caligrafías de soldadura, paralelo a que la mayoría de los trabajos que sí usan clasificación están enfocados a la detección de defectos de soldadura después de proceso, por lo que aún no se conoce, al menos de manera pública, una red neuronal específicamente entrenada para la clasificación de caligráficas de soldadura al momento de la realización de esta investigación. Otro trabajo, relacionado a la presente investigación, pero que aún no se encuentra disponible en el repositorio institucional, es el protocolo de investigación de Alejo Ramírez (2024) de la maestría en ciencias – mecatrónica, el cual presenta un método de clasificación de errores en rebabas de soldadura por punto de una celda de manufactura robotizada aplicando inteligencia artificial. Aunque este trabajo aún no está publicado, por un lado, se resalta la importancia de esta línea de investigación dentro de la facultad de ingeniería y, por otro lado, muestra lo incipiente que está esta línea de investigación, dejando muchas oportunidades de investigación.

1.2 Descripción del problema

Una soldadura defectuosa puede conllevar consecuencias graves, como fallas estructurales, riesgos de seguridad para los trabajadores o usuarios finales, y costos adicionales por reparaciones, retrabajos, tiempos muertos y fallos en el producto final

(Ghimire & Selvam, 2023). La evaluación visual del desempeño de soldadores durante su entrenamiento es realizada por humanos y presenta varias limitaciones como la subjetividad en la interpretación de los defectos, la variabilidad entre diferentes operadores, así como la fatiga visual y condiciones de iluminación inadecuadas pueden llevar a errores y discrepancias en los resultados de la inspección.

Dentro de entornos industriales es común el uso de celdas de soldadura automatizadas preconfiguradas, equipadas con sistemas de retroalimentación, escáneres láser, inspección visual basada en IA o sensores táctiles de trayectoria. Ejemplos de estos sistemas incluyen el Tactile Seam Tracker de Fronius o el sistema Laser Seam Tracking (LST) presente en robots FANUC y Yaskawa. Incluso existen soluciones especializadas para procesos como la soldadura orbital de tuberías como el PipeWizard iX o Rotoweld 3.0, que integran sensores de ultrasonido, visión artificial y control inteligente de trayectoria. Estas opciones ofrecen precisión y repetibilidad de uso relativamente sencillo, pero su costo suele ser elevado, representando una inversión fuerte a considerar.

Estas tecnologías, aunque avanzadas, no son viables para entornos educativos, talleres pequeños o industrias con recursos limitados, que recurren frecuentemente a robots de segunda mano o versiones industriales básicas que carecen de sensores, retroalimentación o algoritmos inteligentes integrados. Para estos casos, una de las principales limitantes es que no existe actualmente una metodología estandarizada que permita caracterizar el proceso o realizar pruebas de forma accesible y reproducible, lo que limita la capacidad de aprovechar el desarrollo de competencias o la mejora de procesos productivos, retrasando la migración a técnicas de clasificación automáticas. Así como tampoco existe como tal una base de datos libre y estandarizada de imágenes de caligrafías o cordones de soldadura que se pueda utilizar para desarrollo de metodologías, entrenamiento y validación de modelos de inteligencia artificial. La mayoría de los estudios se realizan con bases de datos propias o limitadas, y las pocas imágenes digitalizadas que se pueden encontrar para la inspección de soldadura suelen caracterizarse por tener mala calidad y bajo contraste, cualidades que afectan la interpretación y la clasificación. Por lo cual, la replicación de investigación y comparación de resultados se ve muy limitada (Bacioiu et al., 2020; Zhang et al., 2021).

Por lo tanto, no hay una red neuronal preentrenada para soldadura tipo MIG-FCAW, capaz de identificar distintos movimientos de electrodo (caligrafías) y manejar la variabilidad que se pueden presentar en los cordones de soldadura para proporcionar resultados consistentes sin depender de sensores adicionales.

1.3 Justificación

La soldadura representa una de las técnicas más fundamentales en el sector manufacturero, siendo ampliamente utilizada en industrias como la automotriz, aeroespacial, construcción y metalmecánica. Su correcta ejecución es crucial para garantizar la integridad estructural, la seguridad operativa y el desempeño de productos y sistemas. En este contexto, la calidad del cordón de soldadura se convierte en un aspecto crítico que, sin una evaluación adecuada, puede derivar en defectos, fallas funcionales o riesgos operativos (Sen et al., 2018).

Sin embargo, la inspección visual tradicional, ya sea durante el entrenamiento de soldadores o en verificaciones de calidad en campo, continúa dependiendo en gran medida del criterio humano, lo que puede conducir a subjetividades y variabilidad en los resultados, además de ser propenso a variaciones entre operadores y condiciones externas como iluminación, fatiga o suciedad.

En este contexto, el presente proyecto se presenta como primer paso para el desarrollo de tecnología propia, ofreciendo una metodología para la clasificación automática de caligrafías de soldadura MIG-FCAW, basada en procesamiento de imágenes digitales y redes neuronales convolucionales (CNN). Esta metodología comprende desde la metodología para la realización de muestras, la captura controlada de imágenes, preprocesamiento de estas, hasta el entrenamiento de un modelo CNN personalizado e implementación de una interfaz gráfica accesible que automatiza la clasificación y el registro de resultados.

Desde el punto de vista tecnológico, este proyecto tiene la intención de permitirle a instituciones educativas, instructores, operarios o pequeñas industrias que trabajan con robots industriales básicos (muchas veces adquiridos de segunda mano) disponer de un sistema funcional que elimina la dependencia del juicio humano y facilita la evaluación de habilidades motrices o trayectorias programadas, usando infraestructura mínima disponible actualmente como cámaras accesibles, o capacidad de cómputo común, prescindiendo de los sensores avanzados o sistemas de retroalimentación de celdas comerciales preconfiguradas.

En el ámbito científico representa un avance en la aplicación de técnicas de inteligencia artificial en soldadura, un área crítica para el sector manufacturero y de construcción en general, y aun así de las menos estudiada en la automatización industrial. La utilización de CNN para analizar y clasificar caligrafías de soldadura a través de algoritmos neuro difusos de visión puede funcionar como base para el desarrollo futuro de modelos más complejos que integren variables como penetración, transferencia térmica o parámetros usados durante el proceso.

A nivel industrial el sistema propuesto puede utilizarse tanto por el ingeniero de procesos para la definición o caracterización de caligrafías operativas, así como por el inspector o ingeniero de calidad para una verificación rápida con un porcentaje de precisión establecido. La interfaz desarrollada así mismo puede servir como apoyo para prácticas didácticas para el desarrollo y evaluación de la habilidad motriz del soldador en pruebas controladas, eliminando la subjetividad humana del evaluador.

El desarrollo del presente trabajo está vinculado directamente con los Programas Nacionales Estratégicos (PRONACES) establecidos por el Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI, antes CONAHCYT) dentro de la sección “ENERGÍA Y CAMBIO CLIMÁTICO” al estar dirigido al desarrollo de tecnologías de soldadura más limpias y eficientes energéticamente. El uso de esta tecnología permitirá una detección rápida y precisa del estado de los trabajos realizados, facilitando intervenciones tempranas y disminuyendo la cantidad de material desperdiciado y reduciendo significativamente la variabilidad del proceso, o evitar trabajos redundantes, mitigando las emisiones y los residuos industriales. Además de que se asegura una mayor longevidad y seguridad de los productos fabricados, contribuyendo directamente a la sostenibilidad ambiental y la mitigación del cambio climático.

1.4 Hipótesis y objetivos

1.4.1 Hipótesis

El uso de procesamiento de imágenes y una red neuronal convolucional (CNN) WeldingNet puede generar una metodología de clasificación de imágenes de cordones de soldadura de 4 diferentes movimientos de soldadura conocidos como caligrafías (circular, cuadrada, media luna y zigzag) con una precisión igual o superior al 90%.

1.4.2 Objetivo general

Desarrollar una metodología basada en procesamiento de imágenes y una red neuronal convolucional capaz de clasificar e identificar patrones de soldadura (caligrafía de soldadura).

1.4.3 Objetivos particulares

- i. Diseñar e implementar una matriz de pruebas para 4 caligrafías de soldadura MIG (circular, cuadrada, media luna y zigzag).
- ii. Generar una base de datos de 100 imágenes de cordones de soldadura por cada caligrafía.
- iii. Diseñar y desarrollar una arquitectura de red neuronal convolucional (WeldingNet) para patrones al menos 4 caligrafías de soldado.
- iv. Desarrollar una interfaz gráfica de usuario que implemente la metodología de clasificación automática de las caligrafías.

1.5 Planteamiento general

En la figura 2, se muestra un planteamiento general para el desarrollo de este proyecto, dividida en 6 etapas principales, cada una con su respectiva complejidad y consideraciones.

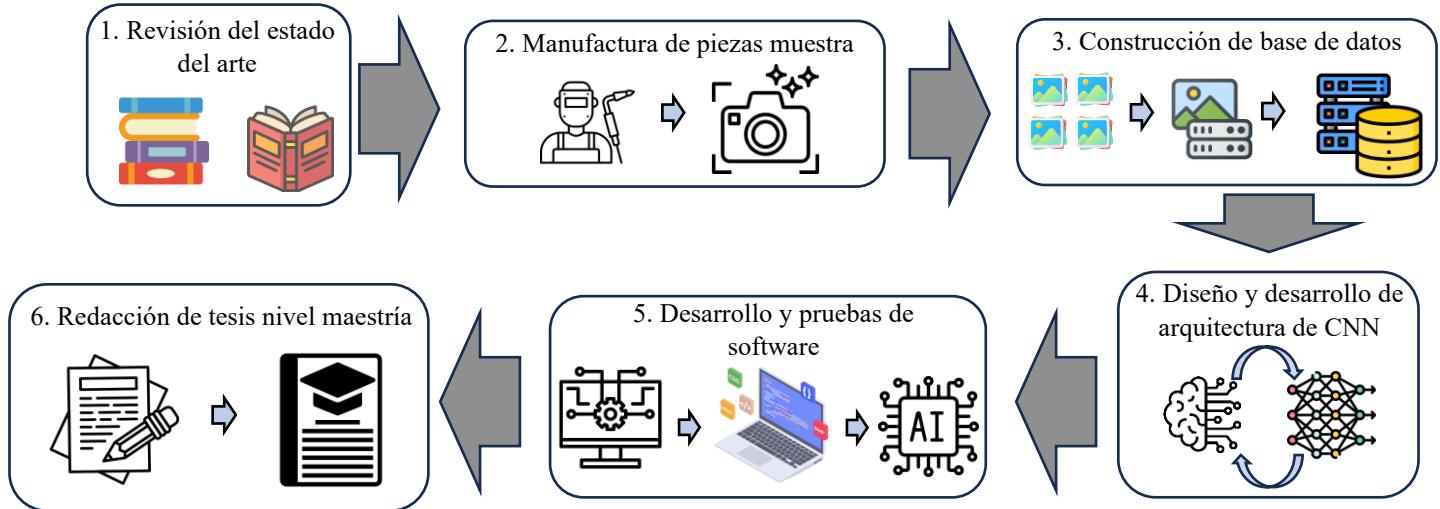


Figura 2 Planteamiento general del presente proyecto.

1.5.1 Revisión del estado del arte

Dentro de esta etapa se revisará la literatura existente, incluyendo artículos científicos e investigaciones más recientes del tema, con el fin de obtener una comprensión y un panorama general del estado de la línea de investigación elegida. Lo anterior servirá como antecedente para identificar los avances más significativos, así como limitaciones actuales para identificar las áreas de oportunidades que se pueden presentar en sistemas de reconocimiento de imágenes enfocado al área de soldadura tipo MIG.

1.5.2 Manufactura de piezas muestra

Esta etapa constará de la manufactura de las caligrafías seleccionadas por un soldador con experiencia o bien con procesos de soldadura robótica, lo que generará un grado de repetibilidad aceptable. Dentro de esta etapa se las recomendaciones que se usarán acorde a para pruebas no destructivas en la norma SNT-TC-1A (Lineamientos pruebas no destructivas) y tomando consideraciones de la ASTM E3 (Pruebas microscópicas y macroscópicas de soldadura), así como especificar la configuración y características de la cámara a usar.

1.5.3 Construcción de base de datos

Generación de una base de datos que contenga al menos 100 imágenes de cordones por caligrafía, considerando y documentando criterios de calidad, resolución, ángulos de captura, condiciones y parámetros de soldadura y materiales. La construcción de la base de datos abarca desde la adquisición de imágenes, incluyendo la aplicación de acondicionamientos y procesamientos mencionados en la sección de fundamentación teórica. La base de datos generada será dividida en conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento se utilizará para ajustar los pesos y parámetros del modelo, mientras que el conjunto de validación servirá para ajustar los hiperparámetros y evitar el sobreajuste. El conjunto de prueba se reservará para evaluar el rendimiento final del modelo. Adicional se implementarán técnicas de aumento de datos (data augmentation), como rotaciones, recortes, escalados y transformaciones de brillo y contraste, con el objetivo de aumentar la variabilidad de los datos de entrenamiento y mejorar la generalización del modelo.

1.5.4 Diseño y desarrollo de la arquitectura de la red CNN

Se procederá al diseño y desarrollo de una CNN específicamente adaptada para la identificación y clasificación de los parámetros clave de soldadura MIG presentes en las imágenes adquiridas. Aquí se abordarán dos enfoques, 1) construir la arquitectura de la CNN desde cero y 2) se aprovecharán técnicas de transferencia de aprendizaje, utilizando modelos preentrenados en tareas similares de visión por computadora, como VGGNet, ResNet, entre otros, que han demostrado eficacia en tareas de clasificación de imágenes. Estos modelos preentrenados proporcionarán una base sólida y pesos iniciales optimizados, lo que podría acelerar el proceso de entrenamiento y mejorar el rendimiento final del modelo.

La arquitectura de la CNN se adaptará y ajustará iterativamente transfiriendo su conocimiento a la tarea específica de clasificación de parámetros de soldadura MIG. Esto implica congelar algunas de las capas iniciales del modelo y ajustar las capas superiores para adaptarlas a la tarea objetivo, así como agregar capas adicionales según sea necesario.

Se probará con diferentes hiper parámetros de la red, tales como el número de capas, filtros y tamaño del kernel, basándose en un análisis continuo del rendimiento en los datos de validación, con el objetivo de mejorar su capacidad de clasificación de los parámetros de soldadura MIG. Además, se seleccionarán cuidadosamente las capas pertinentes de la CNN, así como las funciones de activación y los métodos de regularización necesarios, con el fin de mejorar la generalización del modelo y su capacidad para manejar la variabilidad en los datos de entrada.

La evaluación del rendimiento de la CNN será utilizando métricas clave como precisión, sensibilidad y especificidad en la clasificación de los parámetros de soldadura MIG en nuevas imágenes. Se realizará un análisis detallado para evaluar la capacidad del modelo para generalizar y adaptarse a diversas condiciones reales de soldadura. Además, se emplearán funciones de pérdida adecuadas para el problema de clasificación, como la entropía cruzada categórica, y optimizadores avanzados, como Adam o RMSprop, para actualizar los pesos de la red de manera eficiente. El objetivo final es lograr una tasa de error aceptable en la clasificación de los parámetros de soldadura MIG resultados esperados iguales o superiores a los encontrados en la literatura. Este objetivo servirá como criterio fundamental para determinar el éxito del proceso de entrenamiento y ajuste de la CNN.

Seguidamente se realizarán ajustes finos en la WeldingNet con el objetivo de mejorar su capacidad para clasificar y generalizar los parámetros de soldadura MIG. Se realizará una búsqueda de hiperparámetros y el refinamiento de la arquitectura de la red, con el fin de alcanzar niveles más altos de precisión y eficacia en el proceso de soldadura. Además, se explorarán técnicas de ensamblado (ensemble) y aprendizaje por refuerzo para mejorar aún más el rendimiento de clasificación. En cuanto a las técnicas de ensamblado, se considerará combinar múltiples modelos CNN entrenados de forma independiente, utilizando métodos como el promedio de predicciones o el voto mayoritario, con el objetivo de aprovechar las fortalezas individuales de cada modelo y obtener predicciones más precisas y robustas.

Por otro lado, se evaluará la implementación de técnicas de aprendizaje por refuerzo, donde el modelo CNN se entrenará mediante la interacción con un entorno simulado de soldadura, recibiendo recompensas o penalizaciones en función de la precisión de sus predicciones. Este enfoque podría permitir que el modelo aprenda de forma más eficiente y se adapte mejor a las condiciones cambiantes del proceso de soldadura. Durante este proceso de optimización, se explorarán diferentes configuraciones de la CNN y se ajustarán los parámetros relevantes de manera iterativa. Se prestará especial atención a la selección de funciones de activación, métodos de regularización y optimizadores para mejorar aún más el rendimiento del modelo. Además, se desarrollará una interfaz de usuario intuitiva que permita cargar el modelo entrenado y clasificar nuevas imágenes de patrones de soldadura de manera eficiente. Este componente es crucial para facilitar la aplicación práctica del modelo en entornos industriales, permitiendo una integración sin problemas en los procesos de soldadura existentes.

1.5.5 Desarrollo y pruebas de software

Una vez entrenada y optimizada, la WeldingNet se implementará para su uso práctico. Se validará la efectividad de la CNN en condiciones reales de aplicación, donde se pondrá a prueba la eficacia de reconocimiento de caligrafías de soldadura MIG- FCAW. Para comprobar su eficacia, se utilizará el conjunto de prueba previamente reservado, que permitirá evaluar el rendimiento final del modelo después de haber sido completamente entrenado y validado. Esta fase de validación es crucial para garantizar que la red neuronal pueda generalizar

adecuadamente a nuevos datos y no se limite a memorizar el conjunto de entrenamiento, lo que asegura su utilidad y aplicabilidad en escenarios prácticos del mundo real.

Para asegurar su uso a nivel usuario, así como evitar la configuración errónea del sistema, se desarrollará un software que asegure la realización de los cálculos de la red neuronal a través de una interfaz gráfica de usuario desarrollada en Matlab, la cual servirá de guía al usuario en la utilización de la WeldingNet, teniendo acceso a la base de datos total, y ajustada a los hiperparámetros óptimos específicos.

1.5.6 Redacción de tesis

A lo largo de todas las etapas anteriores, se procederá a la redacción de la tesis para documentar todo el proceso, desde la revisión del estado del arte hasta el desarrollo y validación del software, y presentar los resultados y conclusiones del proyecto.

Capítulo 2

Fundamentación teórica y tecnológica

En este capítulo se presentan los temas necesarios para el entendimiento del desarrollo de una metodología de clasificación de caligrafías de soldadura con el fin de entender los diferentes procesos. Se inicia por la teoría básica para entender el proceso de soldadura tipo MIG, así como una descripción de disciplinas de visión por computador e inteligencia artificial que se plantean para el alcance de la investigación.

2.1 Soldadura MIG-FCAW

2.1.1 Bases teóricas soldadura MIG.

El proceso de soldadura MIG es ampliamente utilizado en la industria a nivel mundial debido a su eficacia y versatilidad (Madavi, Jogi and Luhar, 2021). Este método es especialmente adecuado para la unión de láminas delgadas, al permitir una fácil iniciación y detención del arco, lo que resulta en una alta productividad en procesos automáticos (Kah et al., 2014). A diferencia de otros métodos de soldadura, como el soldado con electrodos revestidos, el proceso MIG no requiere cambios frecuentes de electrodos ni la eliminación de escoria, lo que lo hace ideal para aplicaciones industriales. Utiliza un electrodo consumible y durante la ejecución del proceso se expulsa un gas inerte o semi inerte para proteger la zona de soldadura del oxígeno, contaminación y vapor de agua presentes en el ambiente.

En la soldadura MIG, la alimentación continua del alambre de electrodo y el gas protector se combinan para crear un arco eléctrico estable entre el alambre y el metal base, fundiendo el material del electrodo para formar la soldadura. Este arco se mantiene constante, y el gas protector expulsado de la tobera evita la contaminación del baño de fusión, lo que resulta esencial para mantener la integridad estructural de la soldadura. La energía calorífica necesaria para la soldadura MIG se describe mediante la ecuación 1:

$$Q = I^2 * R * t \quad (1)$$

Donde

Q es el calor generado

I es la corriente de soldadura

R es la resistencia eléctrica

t el tiempo que fluye la corriente.

Este calor derrite el material del electrodo y parte del material base, creando un charco de soldadura que, al solidificarse, forma una unión fuerte y duradera (Weman K. y Lindén G., 2006). Cada parte de la configuración de la soldadura MIG tiene un propósito específico. El equipo básico utilizado en la soldadura MIG incluye un sistema de alimentación de alambre, una fuente de energía, un conjunto de mangueras y cables y una pistola de soldadura que también sirve para dirigir el gas protector. Los ajustes en la configuración del equipo, como la tensión y la velocidad de alimentación del alambre, pueden variar según el tipo de material y el espesor del metal a soldar, lo que requiere un entendimiento técnico detallado para maximizar la eficacia del proceso. En la figura 3 se muestra y posteriormente se describe una configuración típica de soldadura MIG y sus componentes principales.

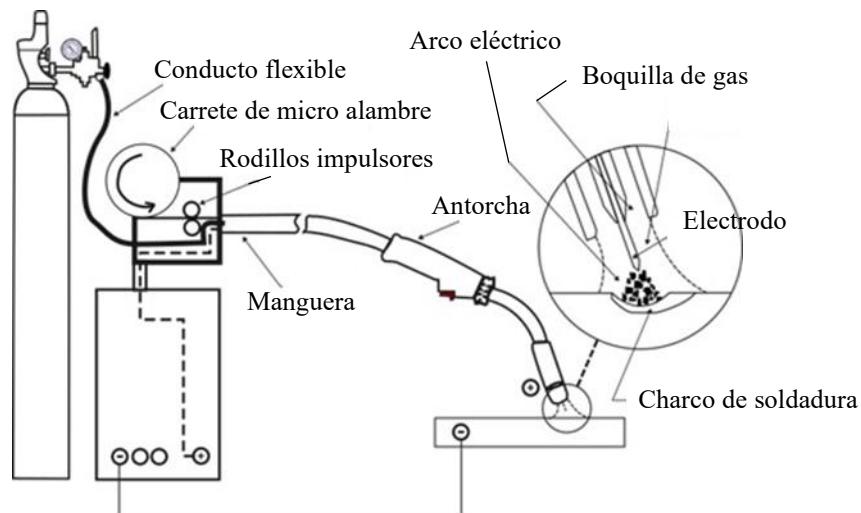


Figura 3 Diagrama esquemático de sistema de soldadura tipo MIG (adaptada de Weman, K., & Lindén, G., 2006).

Como primer concepto se encuentra el cilindro de gas, que contiene un gas protector, que puede ser inerte o activo. Mientras que los gases inertes no reaccionan con el material, los gases activos participan en los procesos de formación del arco eléctrico y del material fundido. Dicho gas es canalizado desde el cilindro a través de un conducto flexible. De manera paralela, se utiliza el carrete de micro alambre que contiene el micro alambre metálico, que actúa como portador de corriente y material de aporte, avanza continuamente a través de rodillos impulsores para reemplazar el metal fundido al pasar por la antorcha, que utiliza el soldador para dirigir el alambre y el gas hacia la pieza de trabajo, siendo aquí donde se genera el arco eléctrico al entrar en contacto con el material a soldar.

Para mediar las condiciones necesarias acorde a la aplicación, el soldador suele ajustar la boquilla de gas para regular y dirigir el flujo de gas protector hacia la zona de soldadura, donde ya se encuentra el electrodo (alambre de soldadura) consumible que se funde junto con el material base para crear la soldadura a través del calor generado por el arco eléctrico creando un charco de soldadura del metal fundido que se solidificará para formar la soldadura. Con base en este funcionamiento, el proceso MIG puede aplicarse en una amplia gama de situaciones y materiales, incluyendo la soldadura de placas delgadas (0.5 mm en adelante) evitando su deformación y distorsión, metales estructurales comunes como acero dulce, acero de baja aleación e inoxidable, aluminio y sus aleaciones, así como metales con revestimiento superficial como el acero recubierto de zinc. Además, puede utilizarse en diversas posiciones y tipos de uniones de soldadura (Sen, et al., 2018; Weman K. y Lindén G., 2006).

Los parámetros de soldadura MIG incluyen el tamaño del micro alambre, el voltaje, la velocidad y corriente de alimentación de alambre, la velocidad de soldadura, la inductancia, el saliente de alambre, la posición de la antorcha y la articulación, los patrones de tejido de la antorcha, la alimentación de hilo pulsado, entre otros (Madavi et al., 2021; Mishara. 2014; Weman & Lindén, 2006). Grietas, porosidad, fusión incompleta y salpicaduras excesivas son solo algunos de los defectos que son frecuentemente producidos por métodos de soldadura. Para mantener la integridad del producto, es crucial asegurar la calidad de la soldadura y detectar estas imperfecciones. Se han empleado numerosas técnicas, como la prueba ultrasonográfica (UT), inspección visual, prueba radiográfica (RT), inspección por partículas magnéticas (MPI), prueba de penetración líquida, entre otras, para asegurar la integridad de las soldaduras (Gupta, et al., 2021; Stravridis, et al., 2018).

2.1.2 Movimientos de electrodo (caligrafías)

En el contexto de los procesos de soldadura por arco, se conoce como caligrafía de soldadura al patrón geométrico o tipo de movimiento que realiza el operador con la antorcha o electrodo durante el avance del cordón. Estos patrones no solo determinan el aspecto visual del cordón, sino que influyen directamente en variables críticas como la penetración, la estabilidad del arco, la distribución del calor y la calidad del depósito metálico (Gaxiola Maya, 2015).

En la práctica profesional, una caligrafía constante, simétrica y adecuada a la posición y tipo de junta suele tomarse como evidencia indirecta de una buena técnica operativa y, por tanto, del nivel de dominio del soldador o buena programación del robot utilizado. En la figura 4 se pueden ver algunos ejemplos de caligrafías.

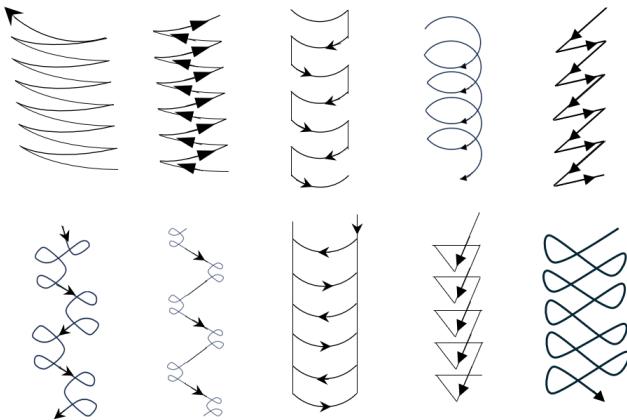


Figura 4 Ejemplo de caligrafías de soldadura.

2.1.3 Posiciones de soldadura y selección de caligrafías.

La elección de caligrafías a usar no es arbitraria. Su correcta ejecución está condicionada por la posición de soldadura, la cual define los principales retos que enfrentará el operador, tales como la gravedad que afecta al baño de fusión, la visibilidad de la junta, el control de escoria y la estabilidad del arco. Las posiciones más reconocidas internacionalmente y estandarizadas por la AWS incluyen:

- Plana (1G): el trabajo se realiza sobre una superficie horizontal; es la más sencilla por efectos mínimos de gravedad.
- Horizontal (2G): la junta está vertical, pero la soldadura se hace en dirección horizontal; requiere mayor control del cordón.
- Vertical ascendente (3G up): se realiza desde abajo hacia arriba, ideal para soldaduras de estructuras.
- Vertical descendente (3G down): utilizada en aplicaciones específicas, requiere rapidez y buen dominio del arco.
- Sobre cabeza (4G): una de las más difíciles, ya que el operador trabaja por debajo de la junta, con riesgo de escoria o gotas calientes cayendo sobre el área.

En la figura 5 se pueden apreciar diferentes posiciones para soldar.

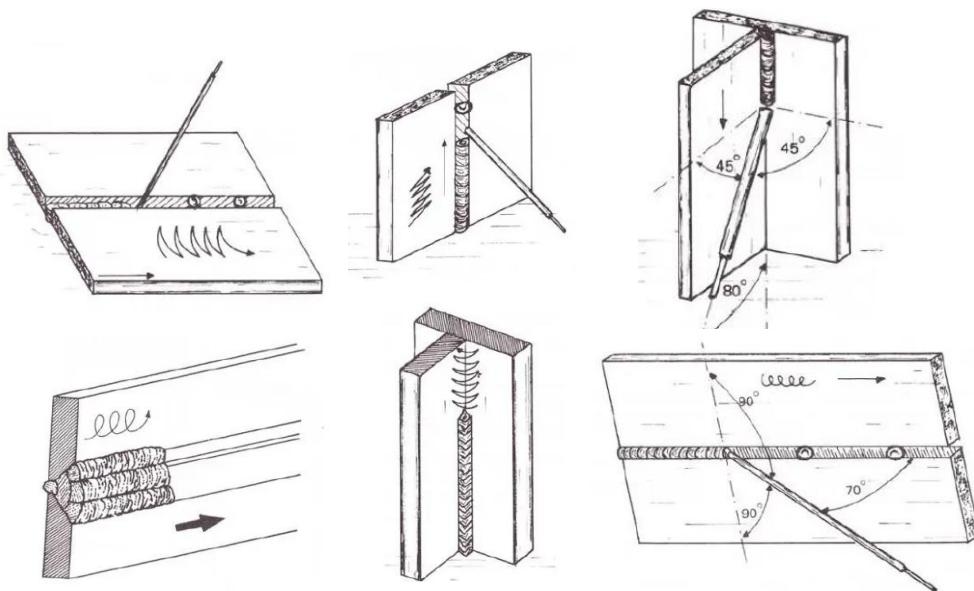


Figura 5 Ejemplos de usos de caligrafías de soldadura tomados de curso de capacitación en soldadura (2.ª ed.) de Gaxiola Maya, editorial LIMUSA. [Págs. 92–151].

Cada tipo de caligrafía responde a una necesidad particular de control del proceso. Según diferentes manuales, y conforme a la práctica técnica, ciertas caligrafías se recomiendan más para determinadas posiciones o funciones del cordón. Según Gaxiola Maya (2015), entre las más comunes en soldadura MIG-FCAW se encuentran:

- Zigzag: apropiado para todas las posiciones, pero particularmente útil en vertical ascendente, ya que ayuda a evitar acumulación de calor y permite subir escoria. Se emplea en cordones anchos y en juntas planas, favoreciendo la liberación de gases.
- Circular: adecuado para trabajos en ángulos interiores o raíces de junta, proporciona buena estabilidad, pero se desaconseja en capas superiores por su bajo volumen de depósito. Ideal en posiciones horizontales o planas donde no se requiere alta acumulación.
- Semicircular o en media luna: ofrece buena fusión en bordes, siendo ideal para juntas biseladas o recargues. Se comporta bien en posiciones verticales y horizontales, ayudando al control lateral del baño de fusión.
- Cuadrada: su trazo en forma de pequeños cuadros permite controlar con precisión la distribución del material. Es muy útil en capas intermedias o en soldadura multipasada, ya que minimiza cavidades y defectos internos.⁴

En la figura 6 se pueden ejemplos para las 4 caligrafías usadas en este proyecto.

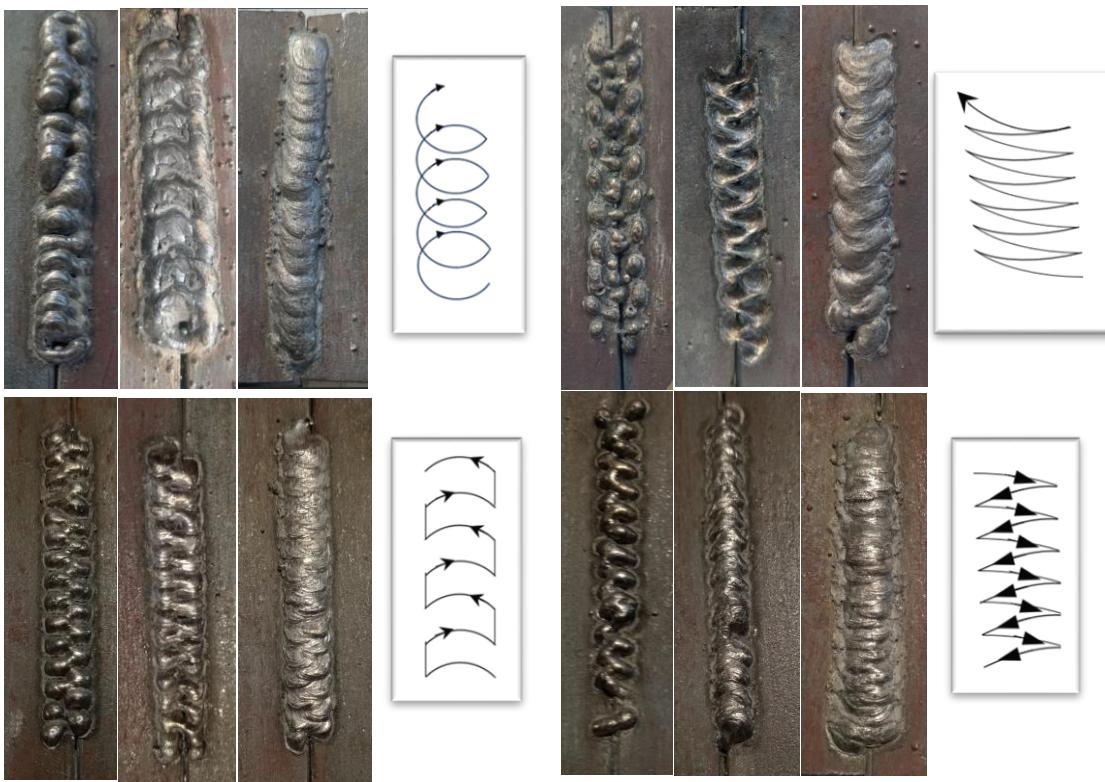


Figura 6 Ejemplos de caligrafías de soldador.

Estas caligrafías, además de su impacto sobre la estética del cordón, funcionan como estrategias operativas adaptativas, que el soldador emplea según la posición, el tipo de junta y el objetivo del pase (raíz, relleno o terminación). Su adecuada elección puede reducir defectos como socavados, falta de fusión o exceso de convexidad. Cada situación exige ajustes en la técnica y caligrafía debido a la forma en que el metal fundido se comporta. Por ejemplo, en posición vertical ascendente, se requiere una caligrafía que evite el sobrecalentamiento y garantice que el charco de fusión no escurra por gravedad, de ahí que el patrón zigzag estrecho o en media luna ascendente sea el más apropiado (AWS, 2020).

La elección inadecuada del tipo de caligrafía puede inducir defectos como falta de fusión, socavados, porosidad o deposición irregular, afectando también la microestructura del cordón, particularmente en la zona afectada por el calor (HAZ). Un mal control del patrón de movimiento puede provocar zonas de sobrecalentamiento, lo cual altera el tamaño del grano, disminuyendo la resistencia a la fatiga (TWI, 2022). Además de su impacto sobre la calidad del cordón, las caligrafías sirven en el control del baño de fusión, permitiendo al operador regular el tiempo de permanencia del arco en cada sección, lo cual incide directamente en la penetración y el perfil térmico de la soldadura. En procesos de soldadura

MIG-FCAW, donde la transferencia metálica y la protección gaseosa están integradas dentro del alambre tubular fundente, un patrón irregular o mal ejecutado puede traducirse en falta de uniformidad del depósito, atrapamiento de escoria, o zonas con falta de penetración o sobrecalentamiento (Gaxiola Maya, 2015; Kah et al., 2012). La caligrafía, por tanto, funciona como una manifestación física de la interacción entre múltiples variables: velocidad de avance, alimentación de alambre, voltaje de arco, corriente de soldadura, y posición.

2.2 Pruebas no destructivas (NDT)

Las pruebas no destructivas son técnicas usadas en la industria para evaluar la integridad y calidad de las soldaduras sin causar daño a los componentes inspeccionados. Estas técnicas permiten la detección de defectos y discontinuidades que podrían comprometer la seguridad y funcionalidad de las estructuras soldadas. Las pruebas no destructivas usualmente van alineadas a la norma ASNT, 2021 (American Society for Nondestructive Testing) aunque según el caso pueden tener más normas aplicables.

2.2.1 Inspección visual

La inspección visual es el método más básico y primer paso en la evaluación de soldaduras. Según la práctica recomendada SNT-TC-1A (enfocada a calificación de personal que realiza las pruebas No destructivas), este método requiere una adecuada iluminación del área de trabajo, suficiente para ver las imperfecciones. La norma NOM-025-STPS-2008 (enfocada en requisitos de iluminación) establece que los niveles mínimos de iluminación para tareas de inspección visual deben ser de 500 lux para talleres de precisión y hasta 1000 lux para procesos que requieren alta exactitud en la distinción de detalles, en el caso de trabajos con soldadura, usualmente se recomiendan más de 1000 lux en adelante.

2.2.2 Radiografía

Este método utiliza radiación ionizante para capturar imágenes del interior de la soldadura en una placa muestra. Es eficaz para detectar defectos internos, como inclusiones de escoria y porosidades internas, que no son visibles a simple vista por la distribución de la luz en la estructura interna de la soldadura, las pruebas se deben realizar siguiendo la ASNT, 2021.

2.2.3 Ultrasonido

Para el método de inspección por ultrasonido, se utilizan ondas sonoras controladas de alta frecuencia para detectar discontinuidades internas en las soldaduras. Este método es

altamente efectivo para identificar defectos no superficiales y evaluar sus profundidades. Los equipos y procedimientos deben ser calibrados adecuadamente para asegurar mediciones precisas acorde la norma ISO 17639 enfocada en lineamientos para pruebas macroscópicas y microscópicas en materiales metálicos.

2.2.4 Partículas magnéticas

Aplicable sólo en materiales ferromagnéticos, este método detecta discontinuidades superficiales e internas al inducir un campo magnético en la pieza y aplicar partículas ferrosas que se acumulan en áreas donde el campo magnético se ve interrumpido por un defecto, de debe de llevar acorde a la ASNT, 2021.

2.2.5 Líquidos penetrantes

Se trata de un método adecuado para materiales no porosos. Este método revela el estado y los defectos superficiales al aplicar un líquido penetrante que se introduce en las discontinuidades, para luego ser visualizado con un líquido revelador.

2.3 Cámaras – sensores de obtención de imágenes

Las cámaras son dispositivos responsables de capturar las imágenes que serán procesadas y analizadas por algoritmos tales como redes neuronales para reconocimiento automático de patrones. Para garantizar que las imágenes capturadas sean adecuadas para su uso en redes neuronales, es crucial considerar varios factores y características de las cámaras y las imágenes.

Dentro de las cámaras digitales usadas para la captura de imágenes, se pueden encontrar cámaras CCD (Charge-Coupled Device) que utilizan un sensor que convierte la luz en señales eléctricas. Son conocidas por su alta calidad de imagen y baja distorsión o bien cámaras CMOS (Complementary Metal-Oxide-Semiconductor) que utilizan tecnología de semiconductores para convertir la luz en señales eléctricas. Son más eficientes energéticamente y suelen ser más rápidas que las cámaras CCD. Muchas veces debido a la complicación propias del fenómeno a estudiar se pueden utilizar cámaras estéreo, que utilizan dos o más sensores para capturar imágenes desde diferentes ángulos, permitiendo la reconstrucción de la profundidad y la percepción 3D.

Para que las imágenes capturadas sean efectivamente utilizadas en redes neuronales, deben cumplir con ciertos requisitos en términos de calidad, resolución y formato,

empezando por la resolución de la imagen. Se considera usar imágenes de alta resolución para capturar detalles finos en la imagen ya que una mayor resolución proporciona más información del objeto de estudio, lo que puede mejorar el rendimiento de la red neuronal. Sin embargo, también aumenta el costo computacional y de almacenaje, aunque normalmente se usa una resolución más baja dependiendo de la aplicación. Una resolución comúnmente utilizada para tareas de clasificación de imágenes (ImagenNet) es de 224x224 píxeles o 256x256 píxeles, aunque para tareas más complejas como la detección de objetos, resoluciones más altas pueden ser necesarias. De igual manera, en cuestión de color suelen tener una profundidad de 24 bits (8 bits por canal RGB) o escala de grises (8 bits). Acerca de la calidad de imagen la nitidez y el enfoque, las imágenes deben ser claras y bien enfocadas, de lo contrario, imágenes borrosas pueden dificultar el aprendizaje de las características por parte de la red neuronal. Así mismo la iluminación debe ser uniforme para evitar sombras y reflejos que puedan introducir ruido en los datos, se puede utilizar una iluminación artificial controlada para minimizar las variaciones debidas a cambios en la luz natural, así como usar un fondo neutro y uniforme ayuda a enfocar la atención en los objetos de interés. En la figura 7 se puede ver un ejemplo de una cámara RGB típica



Figura 7 Cámara RGB comercial Canon Rebel T8i.

2.4 Visión artificial

La visión artificial es la disciplina tecnológica que permite dotar a las máquinas de la capacidad para percibir y comprender el entorno a partir de imágenes digitales acorde a lo que la aplicación específica requiera. Por lo tanto, tratar de dar la capacidad a la máquina de extraer rasgos y características geométricas de objetos en un entorno tridimensional, pero a través de la interpretación de figuras planas. Además de las características geométricas del objeto de análisis, se toman en cuenta diferentes características del material como puede ser el contraste, textura, composición mientras lida con la mitigación de ruido debido al

ambiente cambiante para reducir los errores en la interpretación de datos (Marcos et. al, 2006). El proceso de visión artificial consta de las siguientes etapas:

Captura de la imagen digital: Implica el uso de sensores y la capacidad de convertir la señal del sensor en datos digitales. Los sensores pueden ser cámaras de video, cámaras digitales, escáneres, entre otros dispositivos que convierten la luz en señales eléctricas que luego son digitalizadas (Forsyth & Ponce, 2011).

Preprocesamiento de la imagen: El objetivo del preprocesamiento es mejorar la calidad de la imagen para aumentar las posibilidades de éxito en las etapas posteriores. Esto puede incluir la reducción de ruido, corrección de iluminación y realce de bordes. Técnicas como el filtrado y la normalización son comunes en esta etapa (González & Woods, 2008).

Segmentación: Consiste en dividir la imagen en partes u objetos que la componen. Una segmentación precisa facilita la resolución del problema, ya que permite identificar regiones de interés (ROI) dentro de la imagen. Métodos como la umbralización, la segmentación basada en bordes y la segmentación basada en regiones son utilizados para este propósito (Szeliski, 2010).

Reconocimiento e interpretación: Este proceso implica etiquetar o clasificar un objeto utilizando los descriptores disponibles. La comprensión implica otorgar significado al conjunto de objetos identificados. Algoritmos de aprendizaje automático y técnicas de reconocimiento de patrones son fundamentales en esta etapa para la identificación y clasificación de los objetos dentro de la imagen (Bishop, 2006).

La formación y representación de la imagen es un aspecto crucial en visión artificial, ya que define cómo se captura y se interpreta la información visual. La formación de imágenes implica la captura de información visual mediante sensores que convierten la luz reflejada de los objetos en datos digitales. En la visión artificial, la formación de imágenes se puede describir matemáticamente mediante la función de imagen digital $f(x,y)$, donde “ x ” y “ y ” son las coordenadas espaciales y “ f ” es la intensidad de la imagen en esas coordenadas. Esta función se descompone en dos componentes principales: iluminación $i(x,y)$ y reflectancia $r(x,y)$ (Forsyth & Ponce, 2011):

$$f(x,y) = i(x,y) * r(x,y) \quad (2)$$

Donde:

$f(x,y)$ es la intensidad de la imagen en el punto (x,y) .

$i(x,y)$ es la cantidad de luz incidente sobre la escena.

$r(x,y)$ es la reflectancia de la superficie, que describe la proporción de luz reflejada por los objetos en la escena.

2.4.1 Representación matricial

La imagen digital se almacena en una matriz de tamaño $N \times M$, donde cada elemento $f(i,j)$ representa la intensidad del píxel en la posición (i,j) . Esta representación permite manipular y procesar imágenes mediante diversas técnicas matemáticas y algoritmos, facilitando tareas como la segmentación, el filtrado y la clasificación (González & Woods, 2008).

$$f = \begin{bmatrix} f(1,1) & f(1,2) & \dots & f(1,M) \\ f(2,1) & f(2,2) & \dots & f(2,M) \\ \vdots & & \ddots & \vdots \\ f(N,1) & f(N,2) & \dots & f(N,M) \end{bmatrix} \quad (3)$$

Donde:

$f(N,M)$ es la intensidad del píxel en la fila i , y columna j de la imagen.

N es el número total de filas (altura de la imagen).

M es el número total de columnas (ancho de la imagen).

Cada elemento encontrado de imagen es conocido como píxel y representa la intensidad de la imagen en ese punto específico. Para capturar y representar una imagen de manera que las regiones de interés (ROI) contengan toda la información relevante, es necesario contar con un entorno controlado para asegurar condiciones ambientales óptimas y asegurar la repetibilidad (Martin Sanz & De La Cruz, 2007).

2.4.2 Escala de grises

En el procesamiento digital de imágenes, la conversión a escala de grises permite reducir la complejidad de la imagen al eliminar la información de color sin perder detalles estructurales esenciales. Este proceso consiste en transformar una imagen a color compuesta

por tres canales (rojo, verde y azul) en una imagen monocromática, en la que cada píxel está representado por un solo valor de intensidad luminosa. Esta operación no se realiza mediante un promedio simple, sino mediante una ponderación basada en la percepción del ojo humano, que es más sensible al verde y menos al azul. La ecuación estándar para la conversión a escala de grises es:

$$I_{gris}(x, y) = 0.299 \cdot R(x, y) + 0.587 \cdot G(x, y) + 0.114 \cdot B(x, y) \quad (4)$$

Donde:

- $R(x, y)$, $G(x, y)$, $B(x, y)$ representan los valores del píxel en los canales rojo, verde y azul, respectivamente.
- $I(x, y)$ es la intensidad en escala de grises resultante.

2.4.3 Imagen negativa

La imagen negativa es una transformación simple utilizada en procesamiento de imágenes para realzar contornos o áreas poco visibles, especialmente cuando se trabaja con imágenes con fondos brillantes o condiciones de iluminación difíciles, como sucede frecuentemente en superficies metálicas o soldaduras recién aplicadas.

El proceso consiste en invertir los niveles de intensidad de cada píxel, de forma que los píxeles más oscuros se vuelvan claros y los más claros se vuelvan oscuros. Esta operación es útil para resaltar detalles estructurales que podrían ser difíciles de percibir en la imagen original.

La transformación se realiza mediante la siguiente ecuación:

$$I_{negativo}(x, y) = 255 - I_{gris}(x, y) \quad (5)$$

Donde:

- $I_{gris}(x, y)$ es la intensidad del píxel original en escala de grises.
- $I_{negativo}(x, y)$ es la intensidad del píxel en la imagen negativa.
- El valor 255 representa el nivel máximo de intensidad para imágenes de 8 bits.

Aplicar el negativo de una imagen puede facilitar el análisis automático o visual cuando el fondo y los bordes del objeto de interés tienen intensidades similares o poco contraste, ayudando así en tareas como la detección de contornos o la binarización.

2.4.4 Filtrado de imágenes y convolución discreta

El filtrado de imágenes implica la manipulación de la imagen original mediante la aplicación de una máscara o kernel, que se desplaza sobre la imagen modificando el valor de cada píxel en función de sus vecinos. Esta operación se conoce como convolución discreta en dos dimensiones (2D), y se utiliza comúnmente para tareas como suavizado, detección de bordes o realce de contraste. Matemáticamente, el resultado del filtrado se expresa mediante la siguiente ecuación:

$$g(x, y) = (f * h)(x, y) = \sum_{i=-a}^{a} \sum_{j=-b}^{b} f(x - i, y - j)h(i, j) \quad (6)$$

Donde:

$f(x, y)$ es la imagen original.

$h(i, j)$ es la máscara o filtro (también llamado kernel), que puede ser, por ejemplo, un suavizador o detector de bordes.

$g(x, y)$ es la imagen resultante después de aplicar el filtrado.

a, b determinan el tamaño del kernel, siendo el rango del desplazamiento en las direcciones horizontal y vertical respectivamente.

Esta operación permite que cada píxel de salida $g(x, y)$ sea una combinación ponderada de los píxeles vecinos en la imagen original $f(x, y)$, ponderados por los valores definidos en el kernel $h(i, j)$. Dependiendo del tipo de kernel utilizado, se pueden aplicar diferentes efectos como desenfoque, realce de contornos o eliminación de ruido, lo cual es crucial como paso previo a etapas de segmentación como la umbralización.

2.4.4.1 Filtro promedio

El filtro promedio es una técnica de suavizado utilizada en el procesamiento de imágenes para reducir el ruido y los detalles finos. El objetivo del filtro promedio es reemplazar el valor de cada píxel por el promedio de los valores de los píxeles en su vecindad.

Este proceso tiende a suavizar las variaciones bruscas de intensidad, produciendo una imagen más suave (ver figura 8). Matemáticamente, para una máscara de $M \times N$, el valor del píxel filtrado $I'(i,j)$ se define como:

$$I'(i,j) = \frac{1}{m \times n} \sum_{k=-a}^a \sum_{l=-b}^b I(i+k, j+l) \quad (7)$$

Donde:

$I'(i,j)$ es la intensidad del píxel en la posición (i,j) , en la imagen filtrada

$I(i,j)$ es la intensidad del píxel en la posición (i,j) , en la imagen original

m y n son las dimensiones de la máscara.



Figura 8 Ejemplo de aplicación de filtro promedio.

2.4.4.2 Filtro gaussiano

El filtro gaussiano es otra técnica de suavizado, pero a diferencia del filtro promedio, utiliza una función de distribución normal (gaussiana) para calcular los valores ponderados de los píxeles en la vecindad (ver figura 9). Este filtro es especialmente útil para reducir el ruido mientras se preservan mejor las características importantes de la imagen, como los bordes (Szeliski, R. (2010). El filtro gaussiano aplica una máscara cuyos coeficientes están determinados por la función gaussiana

$$G(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (8)$$

$G(x,y)$ es el valor de la máscara en la posición (x,y)

σ es la desviación estándar de la distribución gaussiana, que controla el grado de suavizado.

x y y son las coordenadas de la máscara con respecto del centro

La imagen filtrada se obtiene convolucionando esta máscara con la imagen original:

$$I'(i, j) = \sum_{k=-a}^a \sum_{l=-b}^b I(i+k, j+l) G(k, l) \quad (9)$$



Figura 9 Ejemplo de aplicación de filtro gaussiano.

2.4.5 Umbralización

La umbralización es una técnica de procesamiento de imágenes utilizada para segmentar imágenes, consiste en separar pixeles en 2 o más clases, en función de sus valores de intensidad, creando umbrales que dividen la imagen en regiones con valores entre 0 y 255; por lo tanto, los valores por debajo del valor más bajo del umbral se establecen en 0, mientras que valores por encima de 255, se establecen en 255 (ver figura 10). Se define por la siguiente ecuación:

$$I_{MB}(i, j) = \begin{cases} 255 & \text{si } I_{MA}(i, j) \geq \text{umbral} \\ 0 & \text{si } I_{MA}(i, j) < \text{umbral} \end{cases} \quad (10)$$

Donde:

$I_{MA}(i, j)$ = se refiere a la intensidad del píxel en la posición (i, j) a la matriz original.

$I_{MB}(i, j)$ = se refiere a la intensidad del píxel en la posición (i, j) en la imagen umbralizada.

Umbral: se refiere a un valor escalar que define los límites y separación de las clases para la nueva matriz



Figura 10 Ejemplo de umbralización a 2 niveles diferentes (64 y 128).

2.4.6 Binarización

La binarización es una técnica derivada de la umbralización, que implica establecer un umbral y asignar el valor 0 (negro) a todos los píxeles que sean menores que dicho umbral, mientras que los píxeles iguales o mayores al umbral se asignan al valor 1 (blanco). De esta manera, la imagen final está compuesta de píxeles que son unos y ceros, formando una representación binaria dos clases: píxeles de fondo y píxeles de primer plano, en función de un umbral específico, con lo cual dependiendo de la aplicación puede ayudar a reducir el cálculo computacional o mejorar la precisión al tener solo el objeto o región de interés en 2 valores (ver figura 11). Matemáticamente puede definirse mediante la siguiente ecuación:

$$I_{MB}(i,j) = \begin{cases} 1 & \text{si } I_{MA}(i,j) \geq \text{umbral} \\ 0 & \text{si } I_{MA}(i,j) < \text{umbral} \end{cases} \quad (11)$$

Donde:

$I_{MA}(i,j)$: se refiere a la Intensidad del píxel en la posición (i,j) de la imagen original

$I_{MB}(i,j)$: se refiere a la intensidad de píxel en la posición (i,j) de la imagen binarizada

Umbral: se refiere a un valor escalar que define los límites y separación de las clases para la nueva matriz.

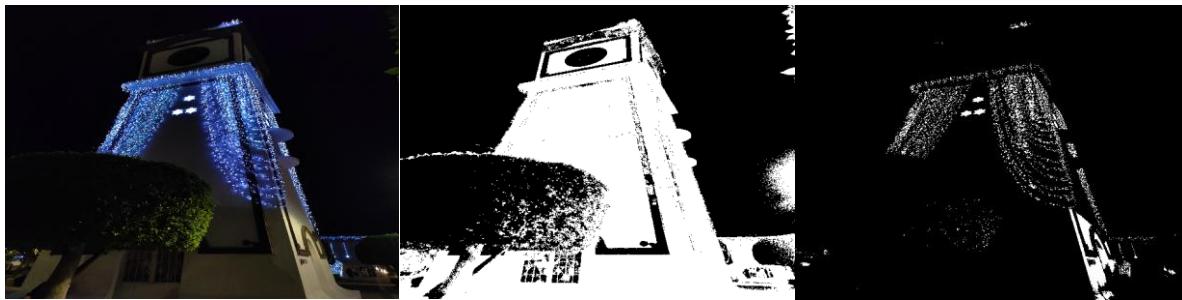


Figura 11 Ejemplo de binarización a 2 niveles diferentes (10 y 128).

2.4.7 Ecualización de contraste

La ecualización de histograma es una técnica utilizada para mejorar el contraste global de una imagen al redistribuir los niveles de intensidad, de manera que se utilice de forma más eficiente todo el rango de valores posibles. Es útil en imágenes con iluminación deficiente o zonas metálicas con reflejos. La ecualización del histograma ajusta los niveles de intensidad de una imagen de manera que el histograma de la imagen resultante sea lo más uniforme posible, es decir, que cada nivel de intensidad tenga una frecuencia de aparición similar (ver figura 12). La transformación de intensidad aplicada a cada píxel se define como:

$$J(i,j) = (L - 1) \sum_{k=0}^{I(i,j)} \frac{h(k)}{MN} \quad (12)$$

Donde:

$J(i,j)$ es la intensidad del píxel en la posición (i,j) en la imagen ecualizada.

L es el número de niveles de intensidad (normalmente 256 para imágenes de 8 bits).

MN es el número total de píxeles en la imagen.

$h(k)$ es el histograma acumulativo de la imagen original.

$I(i,j)$ es la intensidad original del píxel

Primero, se calcula el histograma de la imagen original, que es una representación de la frecuencia de aparición de cada nivel de intensidad en la imagen, luego se calcula el histograma acumulativo, que consiste en la suma progresiva de las frecuencias desde el nivel de intensidad más bajo hasta el nivel de interés, permitiendo tener una visión global de la distribución tonal y finalmente se aplica una transformación de intensidad a cada píxel,

utilizando la ecuación correspondiente, con el objetivo de redistribuir los niveles de gris de manera que la imagen resultante haga un uso más uniforme del rango dinámico disponible. Este procedimiento mejora la percepción visual de detalles y estructuras en imágenes con contraste limitado, y es particularmente útil como etapa de preprocesamiento para análisis más complejos como la segmentación o la detección de bordes.



Figura 12 Ejemplo de ecualización de contraste

2.4.8 Procesamiento morfológico

Es una técnica de procesamiento de imágenes que se basa en la forma y estructura de los objetos dentro de una imagen. Las operaciones morfológicas más básicas son la erosión y la dilatación, que se utilizan para manipular las regiones de primer plano de una imagen binaria.

2.4.8.1 Erosión

La erosión es una operación morfológica que reduce el tamaño de las regiones de primer plano (píxeles blancos) en una imagen binaria. Esta operación se define mediante un elemento estructurante que se desplaza por la imagen. Para cada posición del elemento estructurante, la erosión verifica si este encaja completamente dentro de la región de primer plano de la imagen (ver figura 13). Matemáticamente, la erosión de una imagen binaria A con un elemento estructurante B se define como:

$$A \ominus B = \{z | B_z \subseteq A\} \quad (13)$$

Donde:

A se refiere a la imagen original

B se refiere al elemento estructurante

B_z se refiere al elemento estructurante tras una traslación por z

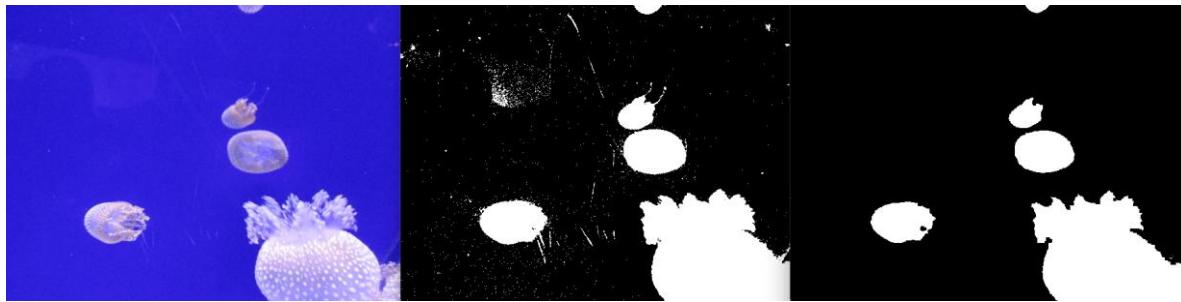


Figura 13 Ejemplo de binarización y erosión.

2.4.8.2 Dilatación

La dilatación es una operación morfológica que aumenta el tamaño de las regiones de primer plano en una imagen binaria. Similar a la erosión, se utiliza un elemento estructurante que se desplaza por la imagen. Para cada píxel, la dilatación verifica si alguna parte del elemento estructurante se superpone con la región de primer plano (ver figura 14). Matemáticamente, la dilatación de una imagen binaria A con un elemento estructurante B se define como:

$$A \odot B = \{z | B_z \cap A \neq \emptyset\} \quad (14)$$

La erosión puede eliminar pequeños puntos de ruido aislados en una imagen binaria, mientras que la dilatación puede restaurar los píxeles perdidos. Así como también se usa la erosión para separar objetos conectados en una imagen, mientras que con la dilatación se pueden volver a unir regiones inconexas, siendo que la combinación de ambas técnicas suele usarse para extracción de contornos o características estructurales importantes.

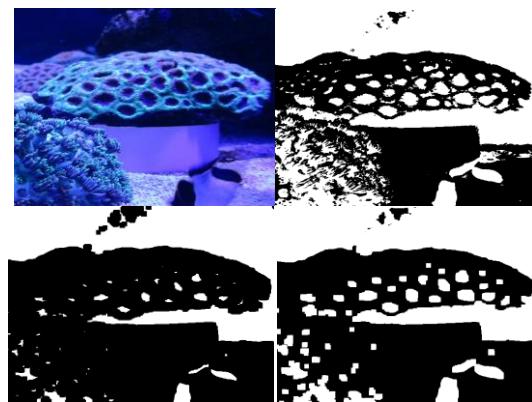


Figura 14 Ejemplo de erosión y dilatación.

2.4.9 Región de interés (ROI)

El concepto de Región de Interés (ROI, por sus siglas en inglés) se refiere a una zona específica dentro de la imagen que contiene la información relevante para el análisis, y sobre la cual se aplicarán las técnicas de segmentación, filtrado o clasificación. Se trata de delimitar el área útil del contenido visual, descartando aquellas regiones que no aportan datos significativos o que podrían introducir ruido en el procesamiento. Ofrece beneficios como reducir el tiempo de procesamiento, mejorar la precisión del sistema de clasificación, y disminuir el riesgo de falsos positivos al enfocarse únicamente en los patrones relevantes.

2.5 Redes neuronales artificiales

La creciente complejidad de los problemas industriales, la disponibilidad de grandes volúmenes de datos y los avances en capacidad computacional han impulsado la adopción de técnicas de inteligencia artificial en múltiples sectores. Entre estas técnicas, las redes neuronales artificiales (RNA) han emergido como una de las herramientas más potentes para la resolución de tareas complejas como clasificación, regresión, reconocimiento de patrones, predicción y control adaptativo.

Inspiradas en el funcionamiento del cerebro humano, las RNA están diseñadas para aprender directamente a partir de los datos, permitiendo modelar relaciones no lineales entre variables y realizar inferencias sobre nuevas observaciones. Su aplicación abarca desde el reconocimiento facial y diagnóstico médico hasta el control robótico y, más recientemente, la inspección automatizada de procesos de manufactura, como la soldadura.

2.5.1 Fundamentos de redes neuronales artificiales

Las redes neuronales artificiales (RNA) son modelos matemáticos y computacionales inspirados en la arquitectura y funcionamiento del sistema nervioso biológico. Fueron propuestas inicialmente por McCulloch y Pitts en 1943, quienes describieron una neurona como una unidad lógica binaria capaz de realizar operaciones simples. Desde entonces, las RNA han evolucionado hacia estructuras mucho más complejas, capaces de resolver tareas de alta complejidad (McCulloch & Pitts, 1943).

Una RNA está compuesta por un conjunto de neuronas artificiales, organizadas en capas: una capa de entrada, una o más capas ocultas y una capa de salida. Las conexiones entre neuronas están definidas por pesos sinápticos, que regulan la intensidad con la que una neurona influye sobre otra. Cada neurona artificial realiza tres operaciones básicas: Recibe

múltiples señales de entrada, las multiplica por sus respectivos pesos, y suma los resultados y les aplica una función de activación. Matemáticamente, este proceso se describe mediante la ecuación:

$$y = \emptyset(\sum_{i=1}^n \omega_i x_i + b)$$

Donde:

x_i son las entradas a la neurona.

ω_i son los pesos sinápticos asociados a cada entrada.

b es un término de sesgo (bias).

\emptyset es la función de activación.

y es la salida de la neurona.

Este modelo permite que la red aprenda comportamientos complejos mediante el ajuste iterativo de los pesos y el sesgo, proceso que se realiza durante el entrenamiento. El aprendizaje se lleva a cabo comparando las salidas producidas por la red con las salidas deseadas y retroalimentando el error mediante algoritmos como retro-propagación (Rumelhart, Hinton & Williams, 1986).

Las redes con una sola capa oculta pueden resolver problemas linealmente separables, pero cuando se requiere mayor capacidad de representación para modelar relaciones no lineales, se emplean redes neuronales profundas, que incluyen múltiples capas ocultas. Este tipo de arquitecturas son capaces de aprender representaciones jerárquicas de los datos, lo que las hace adecuadas para tareas como la clasificación de imágenes, la predicción de series temporales y el análisis de texto.

2.5.2 Fundamentos de redes neuronales artificiales.

El aprendizaje automático (Machine Learning, ML) es una disciplina de la inteligencia artificial que se enfoca en el desarrollo de algoritmos capaces de aprender automáticamente a partir de datos y mejorar su rendimiento sin ser explícitamente programados. A diferencia de los sistemas tradicionales que siguen reglas fijas definidas por

el programador, los algoritmos de ML ajustan internamente sus parámetros con base en la información que reciben, permitiendo reconocer patrones, hacer predicciones o tomar decisiones.

Existen varios tipos de aprendizaje automático, cada uno adecuado para distintos contextos y tipos de datos:

Aprendizaje supervisado: el modelo se entrena utilizando un conjunto de datos etiquetado, donde cada entrada está asociada a una salida esperada. El objetivo es que, tras el entrenamiento, el modelo pueda predecir la salida correspondiente a nuevas entradas. Esta técnica se usa ampliamente en tareas de clasificación y regresión.

Aprendizaje no supervisado: se emplea cuando los datos no están etiquetados. El algoritmo explora la estructura interna de los datos para identificar patrones, agrupamientos o relaciones subyacentes. Es útil en reducción de dimensionalidad y segmentación.

Aprendizaje por refuerzo: el sistema aprende mediante interacción con un entorno, tomando decisiones y recibiendo recompensas o penalizaciones. El objetivo es aprender una política óptima de acción en un entorno dinámico.

Aprendizaje evolutivo: inspirado en la evolución biológica, este enfoque utiliza poblaciones de soluciones que evolucionan mediante selección, mutación y recombinación, como ocurre en algoritmos genéticos. Se aplica frecuentemente en optimización de funciones complejas.

En los últimos años, el avance en cómputo paralelo, el acceso a grandes volúmenes de datos (Big Data) y el desarrollo de nuevas técnicas ha propiciado la aparición de un subcampo denominado aprendizaje profundo (Deep Learning). Este enfoque utiliza redes neuronales profundas, es decir, modelos que contienen múltiples capas ocultas, para aprender representaciones jerárquicas de los datos. A diferencia del ML clásico, que depende en gran medida de la ingeniería de características manual, el aprendizaje profundo es capaz de extraer automáticamente representaciones relevantes desde los datos brutos, como imágenes, texto o sonido.

El aprendizaje profundo ha demostrado una mejora significativa en el rendimiento de modelos aplicados a tareas de clasificación, detección, reconocimiento y predicción, especialmente en áreas como visión por computadora, procesamiento del lenguaje natural y audio. Una de las principales razones de su éxito es su capacidad de componer características de bajo nivel en representaciones abstractas de alto nivel, lo que permite capturar estructuras complejas de los datos (LeCun, Bengio & Hinton, 2015).

2.5.3 Arquitecturas comunes en aprendizaje profundo.

El aprendizaje profundo ha dado lugar al desarrollo de una variedad de arquitecturas de redes neuronales, cada una diseñada para resolver problemas específicos según el tipo y estructura de los datos de entrada. Estas arquitecturas se diferencian principalmente por la forma en que procesan la información, el tipo de conexiones entre las neuronas y el propósito de su entrenamiento. A continuación, se describen brevemente las principales arquitecturas utilizadas en Deep Learning.

2.5.3.1 Redes neuronales profundas (deep feedforward neural networks, D-FFNN)

Son la forma más básica de redes neuronales profundas. Están compuestas por una capa de entrada, varias capas ocultas y una capa de salida. Cada neurona en una capa está completamente conectada a las neuronas de la capa siguiente, y no existen conexiones cíclicas. Este tipo de redes es útil para tareas de clasificación, predicción y regresión. Sin embargo, su rendimiento en tareas con estructura espacial (como imágenes) o temporal (como series de tiempo) es limitado debido a su incapacidad para captar correlaciones locales o dependencias temporales (Goodfellow et al., 2016).

2.5.3.2 Redes neuronales convolucionales (convolutional neural networks, CNN)

Las CNN son especialmente eficaces en el procesamiento de datos con estructura espacial, como imágenes. Su arquitectura incorpora capas de convolución, que permiten extraer características locales, capas de agrupamiento (pooling), que reducen la dimensionalidad, y capas totalmente conectadas, que realizan la clasificación final. Estas redes aprovechan la compartición de pesos y la conectividad local, lo que reduce significativamente el número de parámetros y mejora la eficiencia computacional. Son ampliamente utilizadas en tareas de visión por computadora, como reconocimiento facial, clasificación de objetos y análisis médico por imágenes (LeCun et al., 2015).

2.5.3.3 Redes neuronales recurrentes (recurrent neural networks, RNN) y LSTM

Las RNN están diseñadas para procesar secuencias de datos, como texto o señales temporales, mediante la incorporación de conexiones recurrentes, lo que permite mantener una “memoria” de estados anteriores. Esta propiedad las hace ideales para tareas como traducción automática, reconocimiento de voz y predicción de series temporales. Sin embargo, las RNN tradicionales enfrentan problemas como el desvanecimiento del gradiente, lo cual limita su efectividad en secuencias largas.

Para superar esta limitación, se desarrollaron variantes como las Redes de Memoria a Corto y Largo Plazo (LSTM, por sus siglas en inglés). Las LSTM utilizan puertas internas que regulan el flujo de información, lo que les permite retener dependencias a largo plazo y mejorar la estabilidad del entrenamiento (Hochreiter & Schmidhuber, 1997).

2.5.3.4 Autoencoders (AE)

Los autoencoders son redes neuronales diseñadas para aprender una representación comprimida (codificación) de los datos. Están compuestos por dos partes: un codificador, que transforma los datos de entrada en una representación de menor dimensión, y un decodificador, que reconstruye los datos originales a partir de dicha representación. Son ampliamente utilizados en compresión, eliminación de ruido (denoising), reducción de dimensionalidad y preentrenamiento de modelos más complejos.

2.5.3.5 Redes de creencia profunda (deep belief networks, DBN)

Las DBN son modelos generativos compuestos por múltiples capas de Redes de Máquinas de Boltzmann entrenadas jerárquicamente. Primero se entranan de forma no supervisada para aprender representaciones internas y, posteriormente, se ajustan de forma supervisada. Aunque han sido parcialmente reemplazadas por las CNN y otras arquitecturas más modernas, sentaron las bases teóricas del aprendizaje profundo moderno (Hinton et al., 2006). Cada una de estas arquitecturas resuelve problemáticas específicas dentro del campo del aprendizaje automático. En el caso particular del presente trabajo, se optó por una CNN debido a su capacidad para capturar patrones espaciales complejos en imágenes de soldadura, permitiendo clasificar automáticamente distintos tipos de caligrafías según su trazo característico.

2.5.4 Redes neuronales convolucionales (CNN)

Las redes neuronales convolucionales (CNN) constituyen una arquitectura especializada dentro del aprendizaje profundo, diseñada específicamente para el procesamiento de datos con estructura espacial, como imágenes o señales bidimensionales. Fueron introducidas por LeCun et al. en la década de 1990 para el reconocimiento de dígitos escritos a mano (LeNet-5) y han evolucionado hacia modelos más profundos y complejos como AlexNet, VGGNet, GoogLeNet y ResNet (LeCun, Bottou, Bengio & Haffner, 1998; Krizhevsky, Sutskever & Hinton, 2012).

Las CNN han sido determinantes en el avance del campo de la visión por computadora debido a su capacidad de extraer automáticamente características relevantes a diferentes niveles de abstracción (ver figura 15). A diferencia de las redes neuronales tradicionales, las CNN están construidas sobre el principio de conectividad local y compartición de pesos, lo cual permite reducir drásticamente el número de parámetros del modelo y, al mismo tiempo, explotar las correlaciones espaciales presentes en los datos visuales.

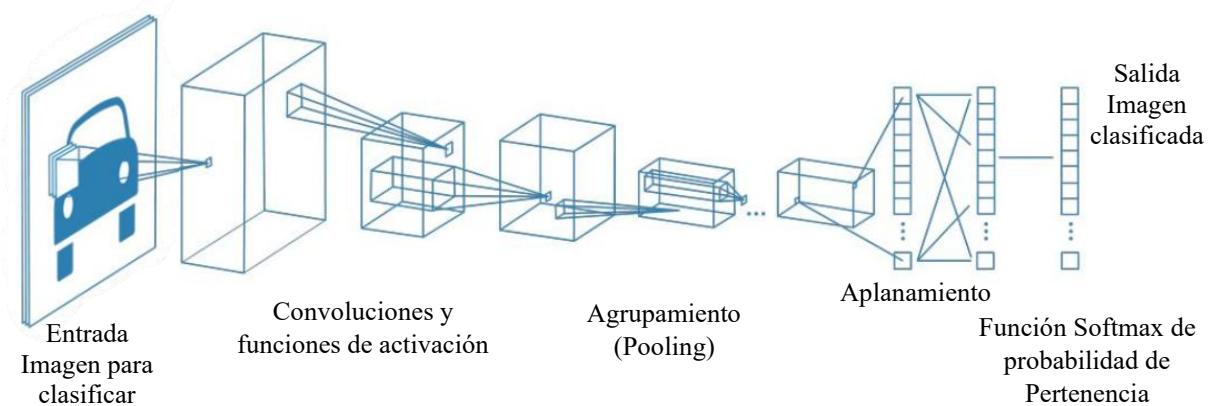


Figura 15 Diagrama general de red neuronal convolucional CNN adaptada de Matlab (2024)

La idea de poder detectar patrones en la caligrafía con el fin de tener caligrafías aptas y adecuadas se pueden prevenir defectos y asegurar que las soldaduras cumplan con los estándares de calidad requeridos. Con una caligrafía adecuada se pueden reducir errores de deformaciones en las piezas de ensamble, se contribuye de manera directa a una de las problemáticas existentes en los programas nacionales estratégicos establecidos por el SECIHTI (antes CONAHCYT) en el rubro de “Agentes Tóxicos y procesos contaminantes”

reduciendo los insumos y desperdicios de material y residuos tóxicos que afectan directamente al medio ambiente, manteniendo la defensa de los derechos ambientales.

El funcionamiento de una red neuronal convolucional se basa en la transformación progresiva de una imagen de entrada a través de múltiples capas especializadas, cada una de las cuales cumple una función específica dentro del proceso de extracción y clasificación de características. Estas capas se organizan de forma secuencial, conformando una arquitectura jerárquica en la que las capas iniciales detectan patrones simples (bordes, esquinas, contornos), mientras que las capas más profundas reconocen formas o estructuras más abstractas. El flujo típico de una CNN está compuesto por tres tipos principales de capas.

Capas de convolución: aplican un conjunto de filtros (o kernels) sobre la imagen de entrada o sobre los mapas de activación previos. Cada filtro recorre la imagen realizando una operación de convolución y generando un mapa de características (feature map) que destaca patrones específicos. La operación de convolución discreta en dos dimensiones se define como:

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (16)$$

Donde:

$I(i + m, j + n)$ es la región local de la imagen que se está evaluando.

$K(m, n)$ es el valor del kernel o filtro que se está aplicando.

$S(i, j)$ es la salida de la convolución.

Capas de activación: después de aplicar la convolución, se utiliza una función no lineal, comúnmente ReLU (Rectified Linear Unit), para introducir no linealidad al sistema. Esta función anula los valores negativos y mantiene los positivos, permitiendo a la red modelar relaciones más complejas:

$$f(x) = \max(0, x) \quad (17)$$

Capas de agrupamiento (pooling): estas capas tienen como objetivo reducir la dimensionalidad espacial del mapa de características manteniendo la información más

importante. La técnica más común es el max-pooling, que toma el valor máximo dentro de una ventana deslizante:

$$y = \max \{x_1, x_2, x_3, \dots, x_n\}$$

Este proceso de convolución, activación y pooling se repite varias veces hasta que los mapas de características alcanzan un nivel de abstracción adecuado. Posteriormente, estos mapas se "aplanan" (flatten) y se pasan a una o más capas totalmente conectadas, que actúan como clasificadores tradicionales mediante funciones como softmax o sigmoid, dependiendo del tipo de salida deseado. El diseño de una CNN se puede ajustar en función del número de filtros, su tamaño, la profundidad de la red, el tipo de funciones de activación y el número de clases a predecir.

2.5.5 Métricas de desempeño

En los sistemas de reconocimiento de patrones mediante aprendizaje automático, la validación del desempeño del modelo se realiza mediante métricas específicas que permiten cuantificar qué tan eficientemente una red neuronal es capaz de clasificar nuevos datos. Estas métricas no sólo evalúan la precisión global del modelo, sino que también permiten identificar desequilibrios, errores sistemáticos y posibles problemas de sobreajuste. A continuación, se describen las métricas más utilizadas:

2.5.5.1 Exactitud global (accuracy)

La exactitud global, conocida comúnmente como accuracy, indica el porcentaje de predicciones correctas que realiza el modelo sobre el total de muestras evaluadas. Representada en la siguiente ecuación:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (19)$$

Donde

TP: Verdaderos Positivos (True Positive)

TN: Verdaderos Negativos (True Negative)

FP: Falsos Positivos (False Positive)

FN: Falsos Negativos (False Negative)

Es útil como métrica general cuando las clases están balanceadas. En problemas multiclase, la exactitud global se puede generalizar como el número de predicciones correctas sobre el total, sin importar la clase, como se observa en la siguiente ecuación.

$$\text{Accuracy} = \frac{\text{Número total de predicciones correctas}}{\text{Número total de muestras}} \quad (20)$$

Sin distinguir entre clases, esta métrica simplemente contabiliza cuántas veces el modelo acertó, sin importar a cuál categoría pertenecía la muestra. Por lo tanto, una exactitud global del 90% indica que 9 de cada 10 imágenes fueron clasificadas correctamente según su caligrafía correspondiente. Sin embargo, si el conjunto de datos está desbalanceado, la exactitud global puede dar una falsa sensación de buen desempeño, ya que un modelo que simplemente clasifique todo como la clase mayoritaria podría alcanzar una exactitud global alta, aunque esté fallando completamente en las clases minoritarias.

2.5.5.2 Precisión por clase (precision)

La precisión mide qué proporción confiabilidad de predicciones positivas realizadas por el modelo para una clase específica fueron correctas. Es decir, de todas las veces que el modelo predijo una clase, cuántas veces acertó:

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (21)$$

Una alta precisión indica que el modelo tiene una baja tasa de falsos positivos, por otro lado, una baja precisión sugiere que el modelo frecuentemente identifica elementos como pertenecientes a una clase cuando en realidad no lo son; En contextos multiclase se calcula la precisión por clase y puede promediarse como macro-promedio (promedio simple entre clases) o ponderado (considerando la proporción de muestras por clase), dependiendo del análisis requerido.

Visualmente, el concepto de precisión puede ilustrarse mediante una analogía de tiro al blanco en la Figura 16, se muestran distintas combinaciones de precisión y exactitud. Un modelo con alta precisión, pero baja exactitud (d) es consistente en sus decisiones, aunque no necesariamente correctas, mientras que un modelo con alta precisión y exactitud (c) logra predicciones correctas y consistentes en la clase objetivo.

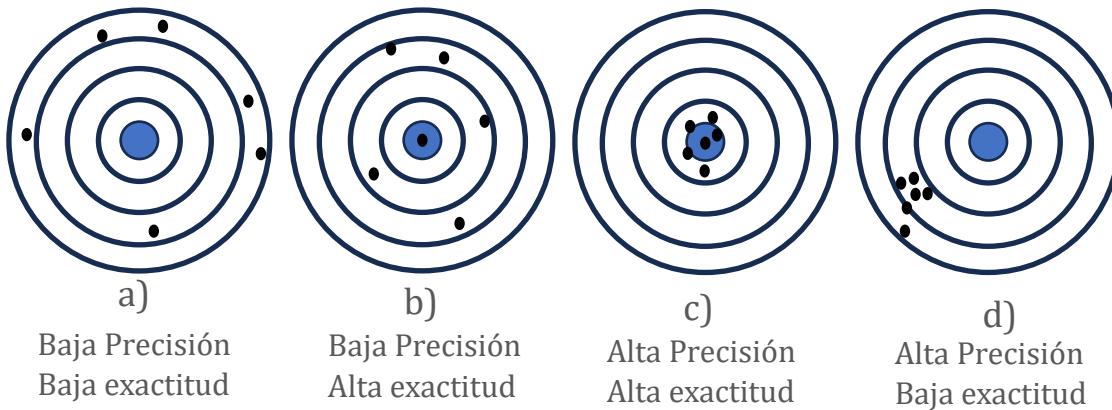


Figura 16 Diagrama explicativo de precisión y exactitud.

2.5.5.3 Sensibilidad (recall)

La sensibilidad (comúnmente conocida como recall o true positive rate) indica cuántos de los elementos que realmente pertenecen a una clase fueron correctamente identificados por el modelo, se define como la proporción de verdaderos positivos (TP) sobre el total de elementos reales de esa clase, es decir, cuántas veces el modelo acertó al identificar una clase entre todas las veces que esa clase estuvo presente:

$$Recall = \frac{TP}{TP + FN} \quad (22)$$

Una alta sensibilidad implica que el modelo rara vez omite elementos pertenecientes a una clase, una baja sensibilidad podría significar que el modelo no detecta una clase incorrecta; Por otro lado, un recall bajo sugiere que el modelo frecuentemente no ahora detecta los elementos de la clase correcta. En problemas de clasificación multiclas, se calcula la sensibilidad por clase y se puede promediar de forma macro o ponderada.

A diferencia de la precisión, que se enfoca en la confiabilidad de las predicciones positivas, el recall se enfoca en la cobertura de la clase real, es decir, cuántos de los casos que debieron detectarse realmente lo fueron. Ambas métricas son complementarias y deben interpretarse conjuntamente para entender el rendimiento completo de un modelo.

2.5.5.4 F1-score

El F1 Score es la media armónica entre la precisión y el recall. Se utiliza como una métrica balanceada cuando se desea considerar tanto los falsos positivos como los falsos negativos:

$$F1 = 2 \frac{Precision * Recall}{Precision + Recall} \quad (23)$$

Este valor se encuentra en el rango de 0 a 1, donde 1 representa un modelo perfecto (con precisión y recall iguales a 1) y 0 indica un desempeño deficiente en ambas métricas. La media armónica utilizada en el F1-score penaliza fuertemente los extremos: si una de las métricas es baja, el F1-score también lo será, aunque la otra sea alta; Esta métrica no se ve afectada por el tamaño de la clase (como ocurre con la exactitud global), y permite detectar escenarios donde el modelo podría parecer correcto por precisión, pero estar omitiendo una gran parte de la clase real (bajo recall), o viceversa. Cuando se tienen múltiples clases, se puede calcular el F1-score para cada una y luego obtener un promedio (macro o ponderado).

2.5.5.5 Matriz de confusión

La matriz de confusión es una representación en forma tabular, donde las filas corresponden a las clases reales y las columnas a las clases predichas por el modelo. Su análisis permite observar no solo cuántas predicciones fueron correctas, sino también qué clases tiende a confundir el modelo entre sí. En esta representación, los valores ubicados en la diagonal principal indican predicciones correctas (cuando la clase real y la predicha coinciden), mientras que los valores fuera de la diagonal reflejan errores de clasificación, señalando la frecuencia con la que una clase fue erróneamente etiquetada como otra.

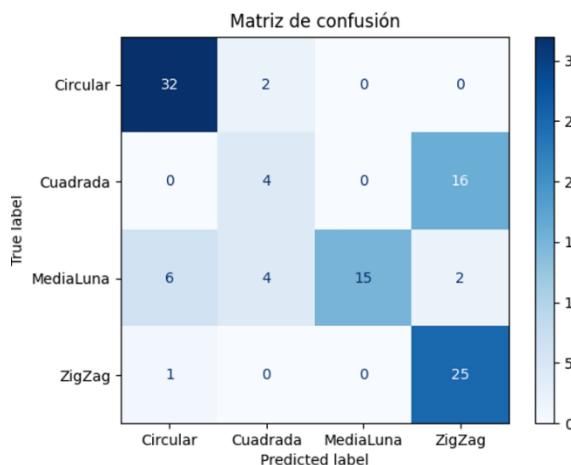


Figura 17 Explicación matriz de confusión

El eje vertical de la matriz representa las etiquetas verdaderas (true label), y el eje horizontal representa las etiquetas asignadas por el modelo (predicted label). En la figura 17 se presenta un ejemplo gráfico de matriz de confusión generada por un modelo de clasificación de caligrafías de soldadura MIG. Se puede observar cómo el modelo acierta en la mayoría de las predicciones (valores altos en la diagonal), pero también muestra errores localizados, especialmente entre clases con patrones visuales similares.

2.6 Software para desarrollo

2.6.1 Phyton

Para el desarrollo de este proyecto se decidió por el lenguaje de programación Python. Python cuenta con diversas bibliotecas diseñadas para simplificar tareas complejas, optimizar procesos y garantizar una integración eficiente de distintas funcionalidades. Entre las herramientas empleadas para el desarrollo de este proyecto, destacan:

Tkinter: Esta biblioteca, incluida de manera nativa en Python, permite la creación de interfaces gráficas de usuario personalizables (Shipman, 2013).

OpenCV: Utilizada para el preprocesamiento de imágenes y su representación visual en interfaces. Esta biblioteca facilita la manipulación y transformación de imágenes en tiempo real, desde tareas básicas como redimensionamiento y filtrado hasta funciones avanzadas como segmentación y análisis de bordes (Bradski & Kaehler, 2008).

TensorFlow/Keras: Estas bibliotecas proporcionan una infraestructura optimizada para implementar, entrenar y evaluar redes neuronales convolucionales. Su integración con Python permitió la automatización del flujo de trabajo desde el procesamiento inicial hasta la inferencia (Abadi et al., 2016).

Matplotlib: Para la generación de gráficos y la visualización de resultados del entrenamiento y validación del modelo. Esta herramienta se utilizó en la interfaz para mostrar estadísticas de desempeño en tiempo real (Hunter, 2007).

Python se posiciona como una herramienta clave para el desarrollo de aplicaciones en proyectos de inteligencia artificial debido a su flexibilidad y a la constante evolución de su ecosistema de bibliotecas, lo que garantiza la compatibilidad y la facilidad de implementación de futuras mejoras en el sistema.

2.6.2 RobotStudio

RobotStudio es un software desarrollado por ABB que permite la simulación y programación de robots industriales. Este programa es ampliamente reconocido en la industria debido a su capacidad para emular con precisión entornos industriales y facilitar el diseño, prueba y optimización de rutinas robóticas sin necesidad de interrumpir procesos productivos (ABB Robotics, 2023). La plataforma permite trabajar en un entorno completamente virtual donde se pueden configurar modelos detallados de robots, herramientas y trayectorias, ofreciendo una visión realista de cómo se ejecutarán las operaciones en condiciones reales (ver figura 18).

Una de las características principales de RobotStudio es su capacidad para garantizar la precisión y repetibilidad en los movimientos programados. Esto es relevante en procesos donde la uniformidad en las trayectorias es fundamental. Mediante el uso de módulos como RobotWare y herramientas específicas de simulación, el software permite definir parámetros detallados, como la velocidad, orientación y ángulo de la herramienta, adaptándose a los requisitos particulares de cada aplicación (ABB Robotics, 2023).



Figura 18 Imagen ejemplo RobotStudio adaptada de abb.com (2024)

Además de su precisión, RobotStudio destaca por su versatilidad al permitir la programación de trayectorias personalizadas mediante herramientas como Path Editor. Esta funcionalidad resulta crucial para aplicaciones que requieren patrones complejos, como las caligrafías de soldadura en procesos MIG. Por lo que se pueden configurar patrones de forma precisa, asegurando una distancia constante entre las pasadas y una cobertura uniforme en el área de trabajo (ABB Robotics, 2023).

2.6.3 Matlab

Para el desarrollo de este proyecto se utilizará el software de Matlab debido a las herramientas que ya tiene incluido el programa, sobre todo para el desarrollo de interfaz gráfica. MATLAB es particularmente popular en la comunidad de investigación y desarrollo debido a su potente capacidad de visualización y su facilidad para realizar cálculos complejos. Sus capacidades gráficas permiten a los usuarios desarrollar aplicaciones con interfaces gráficas de usuario (GUIs) de manera sencilla y eficiente. Además, proporciona un toolbox específico para el procesamiento de imágenes (Image Processing Toolbox) que incluye funciones para la segmentación, filtrado, transformaciones geométricas, análisis morfológico, y mucho más.

Las interfaces gráficas de usuario (GUI, por sus siglas en inglés) ofrecen una manera intuitiva de interactuar con aplicaciones mediante elementos visuales, como botones, menús o deslizadores, eliminando la necesidad de escribir comandos o aprender un lenguaje de programación. En el entorno de MATLAB, las aplicaciones pueden ser desarrolladas como programas autónomos que integran una GUI para automatizar tareas específicas o cálculos complejos. Muchas herramientas especializadas dentro de MATLAB, como Signal Processing Toolbox o Control System Toolbox, ya incluyen interfaces diseñadas para facilitar su uso. Además, los usuarios pueden crear sus propias aplicaciones con GUI personalizadas para compartirlas o adaptarlas a necesidades particulares, lo que incrementa la accesibilidad y la funcionalidad de las soluciones desarrolladas (MathWorks, s.f.).

Capítulo 3

Metodología

El flujo metodológico general planteado en este proyecto se ilustra en la figura 19, que se estructura en seis etapas principales interconectadas. Estas etapas abarcan desde la fabricación de los cordones de soldadura, con recomendaciones, hasta la validación del modelo desarrollado y creación de una interfaz para usuario.

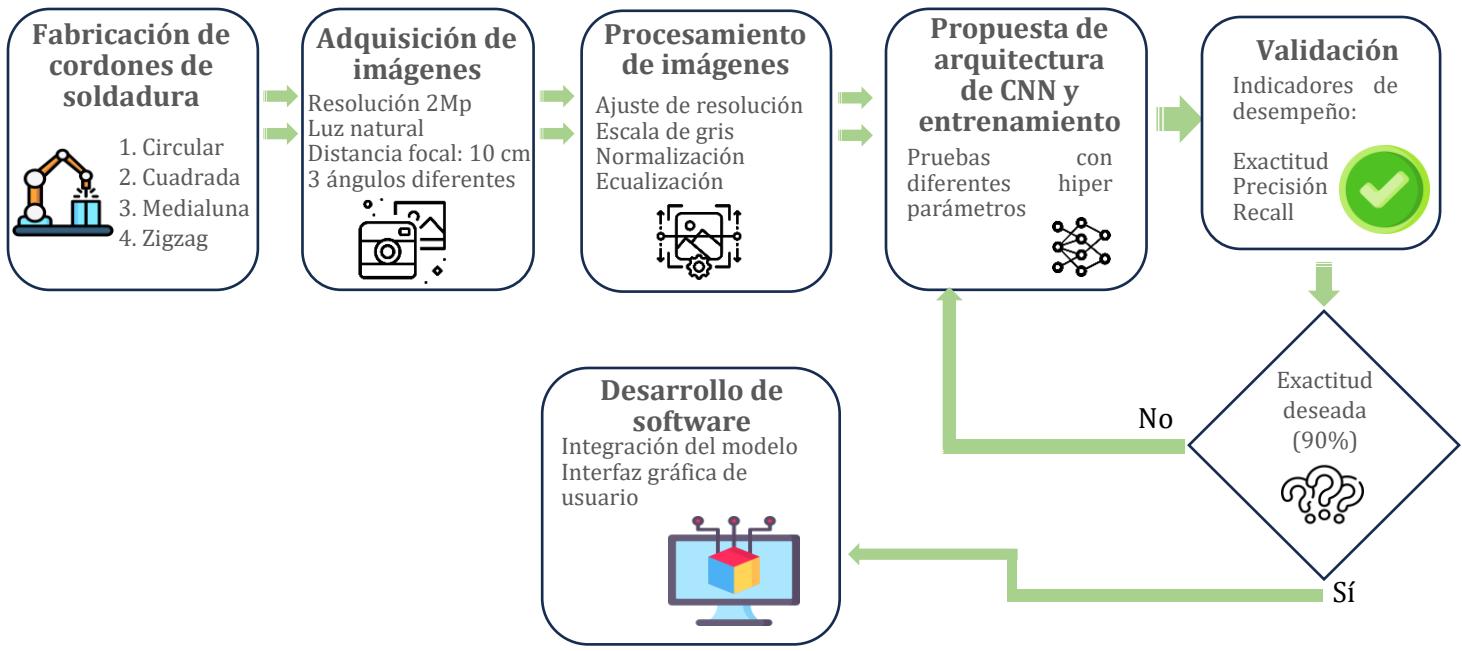


Figura 19 Metodología general planteada

3.1 Fabricación de cordones de soldadura

En esta fase se lleva a cabo la generación de patrones de soldadura predefinidos (caligrafías) sobre soleras metálicas utilizando un robot industrial. Esta actividad permite contar con una base de datos propia y controlada que sirva tanto para el entrenamiento del modelo de clasificación como para su validación. La ejecución de esta etapa se estructuró acorde al diagrama mostrado en la figura 20, e incluye desde el reconocimiento del equipo y herramiental, hasta la programación de trayectorias y la construcción de una matriz de pruebas.

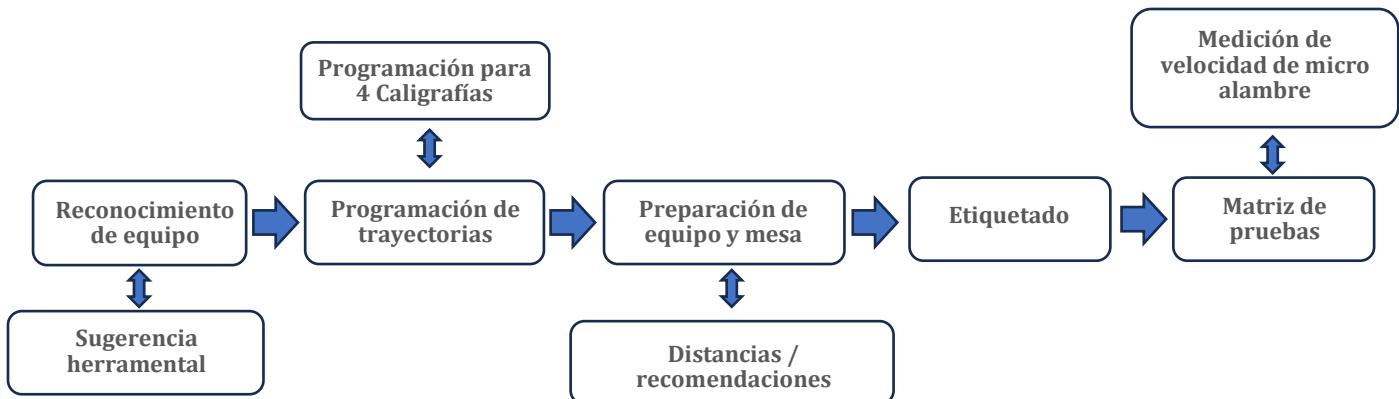


Figura 20 Metodología seguida para fabricación de cordones

3.1.1.1 Reconocimiento del equipo.

La etapa de fabricación de cordones de soldadura se desarrolló en el laboratorio CETEVI, ubicado en el Campus Centro Universitario de la Universidad Autónoma de Querétaro (UAQ), donde se tiene instalada una celda robótica equipada con el sistema necesario para simular condiciones industriales de soldadura asistida por robot. El componente principal de esta celda fue un robot ABB IRB 1410, de seis grados de libertad, diseñado para manipulación ligera y adaptado para aplicaciones de soldadura por arco (ver figura 21). Este modelo tiene una capacidad de carga útil de 5 kg, un alcance máximo de 1.44 metros y una repetibilidad de ± 0.03 mm, lo que lo convierte en una opción confiable para tareas que requieren precisión y repetibilidad constante en trayectorias preprogramadas (ABB Robotics, 2023).



Figura 21 Robot ABB IRB 1410 y controlador ABB IRC5 M2004

El robot fue controlado mediante un sistema ABB IRC5 M2004. Durante el reconocimiento inicial del equipo se verificaron la calibración de ejes, el estado del controlador, los límites físicos del área de trabajo y los requerimientos de seguridad para la operación en celda. En cuanto al sistema de soldadura, se empleó una máquina VOL-MIG110, clasificada dentro del proceso FCAW (Flux-Cored Arc Welding). Esta soldadora opera con una entrada de 110 V CA, con una potencia nominal de aproximadamente 2.5 kVA, y ofrece control manual de la velocidad de alimentación del micro alambre y del voltaje de soldadura. A diferencia de sistemas más avanzados que integran comunicación digital con el robot, esta fuente fue operada de forma independiente y manual, permitiendo únicamente el control del encendido, el avance de hilo y el voltaje mediante diales analógicos.

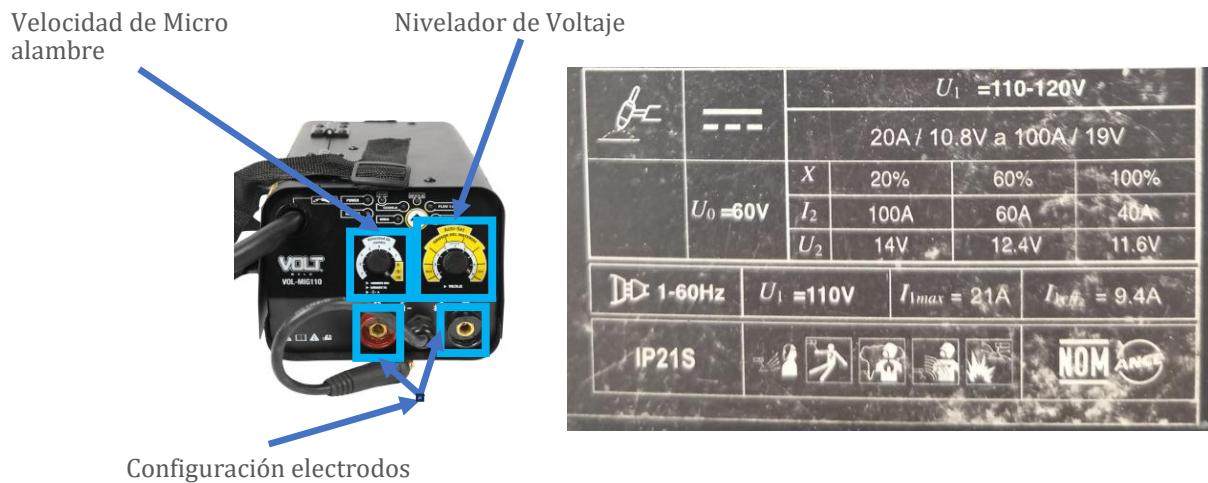


Figura 22 Máquina VOL-MIG110

En el panel frontal de la soldadora VOL-MIG110, se dispone de potenciómetros analógicos rotativos que permiten regular tanto la velocidad de alimentación del alambre como el voltaje de soldadura. Estos potenciómetros están directamente relacionados con la potencia de salida del sistema, permitiendo al operador realizar ajustes proporcionales a la corriente y voltaje nominal. Según la placa técnica del equipo (ver figura 22), los valores de salida varían dentro de un rango típico de 20 A / 15 V hasta 100 A / 19 V en condiciones de trabajo al 100% del ciclo.

La relación entre los potenciómetros y la salida eléctrica es lineal, es decir, al incrementar el nivel de ajuste del potenciómetro, se incrementa la potencia efectiva entregada en el arco. Esto resulta útil para adaptarse a las necesidades del proceso y a las propiedades

del material base. Cabe destacar que, de acuerdo con la especificación del fabricante, el equipo opera con una tensión de entrada de 110-120 V AC, y entrega un voltaje de circuito abierto de hasta 60 V, con una corriente máxima de salida de 100 A y un consumo de hasta 35 A en su máxima exigencia.

En cuanto al material base, se utilizaron soleras de acero dulce cortadas en tramos de 8 cm de longitud por 1 pulgada de ancho y 6 mm de espesor. Este material fue seleccionado por su bajo costo, disponibilidad y soldabilidad estándar bajo condiciones FCAW. Las piezas se prepararon utilizando una cortadora de disco y se almacenaron clasificadas según tipo de caligrafía a implementar. La elección de esta configuración responde al enfoque principal del proyecto: diseñar una metodología replicable en contextos donde los recursos tecnológicos pueden ser limitados. Este reconocimiento de equipo permitió determinar tanto las capacidades como las limitaciones del entorno experimental, sobre las cuales se fundamentó el diseño de los herramientales y las rutinas de soldadura descritas en los siguientes apartados.

3.1.1.2 Sugerencia de herramiental

Con el objetivo de garantizar una correcta orientación y fijación de la antorcha de soldadura en el extremo del robot (Tool Center Point, TCP), se diseñó un herramiental mecánico personalizado, inspirado en herramientas comerciales utilizadas en aplicaciones semiautomáticas de soldadura. La referencia de diseño fue una antorcha con cuello curvo comúnmente empleada en procesos MIG, que permite dirigir el hilo metálico de forma controlada hacia el charco de fusión (ver figura 23).



Figura 23 Herramental usual para soldadura robótica

El soporte fue fabricado en acero dulce y montado sobre una base metálica fija, que se acopla de forma directa al sistema de acoplamiento del robot ABB IRB 1410. Su función principal es mantener el ángulo de inclinación constante entre la antorcha y la superficie de

trabajo durante el desplazamiento del robot, garantizando así que el cordón de soldadura conserve una geometría estable en todas las pruebas. El diseño fue dimensionado para asegurar un alineamiento constante del TCP con el plano medio del material base, en un tramo de al menos 25 cm de recorrido efectivo, permitiendo aplicar trayectorias rectas, semicirculares, cuadradas y en zigzag sin interferencias. Este soporte no cuenta con grados de libertad automatizados, por lo que todos los ajustes de inclinación o posición deben realizarse de forma manual antes de iniciar cada rutina. Sin embargo, esta decisión fue deliberada con el fin de preservar la simplicidad operativa del sistema, especialmente útil para usuarios con experiencia limitada en robótica.

Para la fijación del material de prueba se utilizó una plantilla modular diseñada específicamente para este proyecto, capaz de mantener múltiples piezas metálicas alineadas sin desplazamientos durante el proceso de soldadura. El fixture está compuesto por dos soleras de mayor longitud colocadas de forma paralela sobre una mesa metálica plana, fijadas mediante imanes angulados industriales tipo ON/OFF, los cuales ofrecen una retención firme pero fácilmente ajustable (ver figura 24).

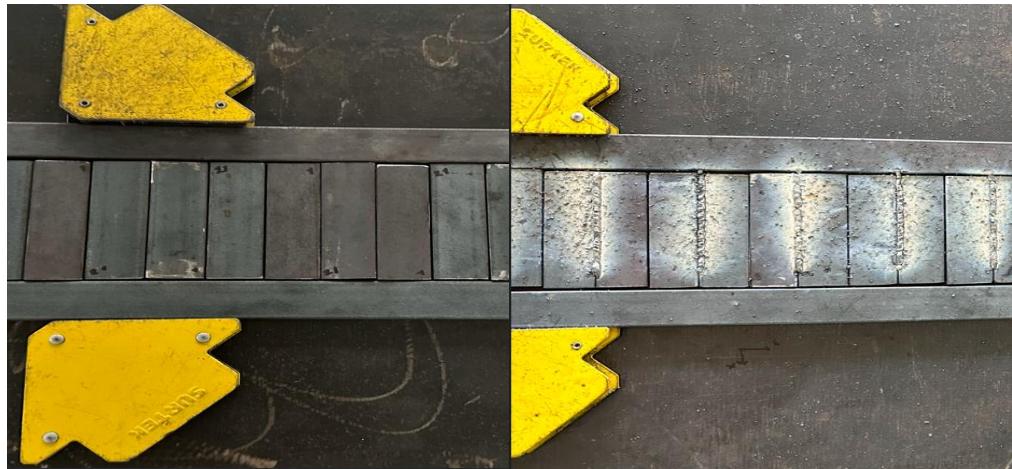


Figura 24 Plantilla de proceso, antes y después de uso (WeldingNet).

Esta plantilla fue diseñada para alojar soleras separadas equitativamente en una sola fila, permitiendo realizar pruebas secuenciales sin necesidad de reconfigurar el sistema entre cada una. Su naturaleza modular facilita también el reemplazo de piezas una vez concluido cada ciclo de soldadura, lo que acelera los tiempos de experimentación. Una de las ventajas clave de esta propuesta es que el fixture no es completamente rígido, sino que puede ser ajustado manualmente por el operador. Esta característica es especialmente valiosa en

entornos educativos o en laboratorios de pruebas donde pueden presentarse colisiones menores, cambios de herramienta o movimientos no previstos. En tales casos, el operario puede corregir la posición del fixture o de las soleras sin necesidad de herramientas ni desmontajes complejos.

No obstante, esta flexibilidad tanto en plantilla como en sujeción de antorcha implica que el sistema requiere revisión frecuente y reajuste visual, particularmente después de cada evento de colisión o cambio en la programación del robot. Esta medida preventiva fue integrada como parte del protocolo de operación del laboratorio.

3.1.2 Programación de trayectorias

En esta sección se deben definir y parametrizar los movimientos que el robot debe seguir para replicar las caligrafías seleccionadas (lineal, zigzag, circular y medialuna), con el fin de crear una base de datos controlada que represente distintos patrones operativos. Esta lógica fue concebida para que pueda implementarse ya sea mediante un programa en Matlab o, incluso, en una hoja de cálculo tipo Excel, facilitando su comprensión y replicación.

En los entornos de robótica industrial, los movimientos pueden clasificarse generalmente en dos tipos: MoveL (Movimiento Lineal) en donde el extremo de la herramienta se desplaza en línea recta entre dos puntos en el espacio cartesiano y MoveC (Movimiento Circular) en donde el desplazamiento describe un arco de círculo definido por tres puntos (un inicio, un punto intermedio y un punto final).

Para estandarizar los movimientos de caligrafía, se definieron tres variables principales que rigen la generación de las trayectorias: largo del cordón (L) es la longitud total que se desea recorrer en la dirección principal del avance; ancho del cordón (A) que determina el desplazamiento lateral respecto al eje de avance; y paso (P), que corresponde a la distancia entre cada ciclo o elemento repetitivo dentro de la caligrafía. Estas variables fueron pensadas para ser ajustables, permitiendo generar múltiples versiones de cada patrón con distinta geometría y, por ende, distintos retos visuales y técnicos. El cálculo automático de los puntos intermedios permite la exportación de las coordenadas generadas a programas compatibles con el entorno ABB RobotStudio o su escritura directa en código RAPID.

A partir de estas variables, se define:

$$n = \frac{L}{P} \quad (24)$$

Donde n representa la cantidad de repeticiones (ciclos) del patrón en el recorrido total. Esta ecuación se utiliza para calcular cuántas veces se repite un mismo ciclo de movimiento a lo largo de un trayecto de longitud L , permitiendo el diseño iterativo y parametrizado de la trayectoria. Además, el centro inicial de la antorcha se define como punto base (X_0, Y_0, Z_0) , desde el cual se construyen los desplazamientos en función de los parámetros definidos.

3.1.2.1 Trayectoria cuadrada

La caligrafía tipo cuadrada se caracteriza por una secuencia de desplazamientos rectilíneos que simulan la construcción de pequeños cuadros concatenados a lo largo del sentido de avance. Este patrón es particularmente útil para generar depósitos de material más amplios, adecuados en situaciones donde se requiere reforzar la sección transversal del cordón o garantizar mayor penetración en soldadura por acumulación.

3.1.2.2 Trayectoria zigzag

La caligrafía de tipo zigzag se caracteriza por un patrón oscilante sobre el eje lateral, que recorre sucesivamente ambos lados del eje de la junta mientras avanza de forma continua en la dirección principal del cordón. Este patrón permite una mejor distribución del calor, favorece el desprendimiento de escoria y facilita la fusión en los bordes del cordón. Por ello, se considera particularmente útil en posiciones verticales ascendentes y en situaciones donde se requiere controlar la acumulación térmica.

3.1.2.3 Trayectoria semicircular (medialuna)

La caligrafía de tipo media luna se caracteriza por simular una trayectoria oscilatoria semicircular invertida (tipo "U"), en la que el electrodo traza un patrón de vaivén a través de una serie de movimientos curvos. Este tipo de trayectoria es ampliamente utilizada en la práctica de soldadura para lograr una mejor fusión en bordes, especialmente en juntas biseladas o zonas donde se requiere una distribución uniforme de calor y material en los extremos laterales del cordón. Este patrón también es útil en aplicaciones donde se busca suavizar las transiciones térmicas a lo largo de la unión, dado que su geometría favorece una menor concentración puntual de energía y una cobertura progresiva del ancho del cordón.

3.1.2.3 Trayectoria circular

La trayectoria tipo circular consiste en la generación repetitiva de bucles cerrados que simulan movimientos rotacionales completos del electrodo a lo largo de la junta. Este patrón es empleado tradicionalmente por soldadores para asegurar una fusión homogénea del material de aporte, especialmente en aplicaciones donde se requiere control térmico sobre zonas amplias del cordón o una deposición uniforme a lo largo de juntas críticas. Además, esta caligrafía permite explorar el comportamiento térmico y geométrico del cordón en procesos continuos sin interrupciones angulares.

3.1.3 Preparación de equipo y mesa

La correcta preparación del equipo y de la mesa de trabajo se debe de llevar a cabo para asegurar la repetibilidad del proceso, así como la estabilidad y seguridad durante la ejecución de las rutinas programadas por el robot. Esta etapa involucra el ajuste inicial de la antorcha, la configuración del espacio de trabajo y la verificación de las distancias recomendadas para procesos de soldadura.

La distancia entre la boquilla de contacto y la superficie de trabajo debe mantenerse entre 8 y 9 mm. Según el Curso de Capacitación en Soldadura de Gaxiola Maya (2012, p. 142), esta distancia permite mantener la estabilidad del arco y una correcta transferencia térmica. Una distancia menor puede ocasionar obstrucción con el cordón previamente depositado, dificultando el avance o deformando el cordón en cuestión. Por el contrario, una distancia mayor provoca interrupciones en el arco, produciendo una flama inestable, pérdida del suministro del micro alambre y formación de porosidades o cortes en la continuidad del cordón. Este fenómeno obliga a reiniciar el ciclo, interrumpiendo el flujo automatizado.

Dado que el sistema de herramiental utilizado para sujetar la antorcha fue pensado como herramienta adaptable, no cuenta con un sistema de fijación rígida. Por ello, se requiere realizar un ajuste manual de altura previo a cada serie de pruebas, lo cual fue verificado con una regla graduada colocada perpendicular al plano de trabajo, como se muestra en la figura 25.

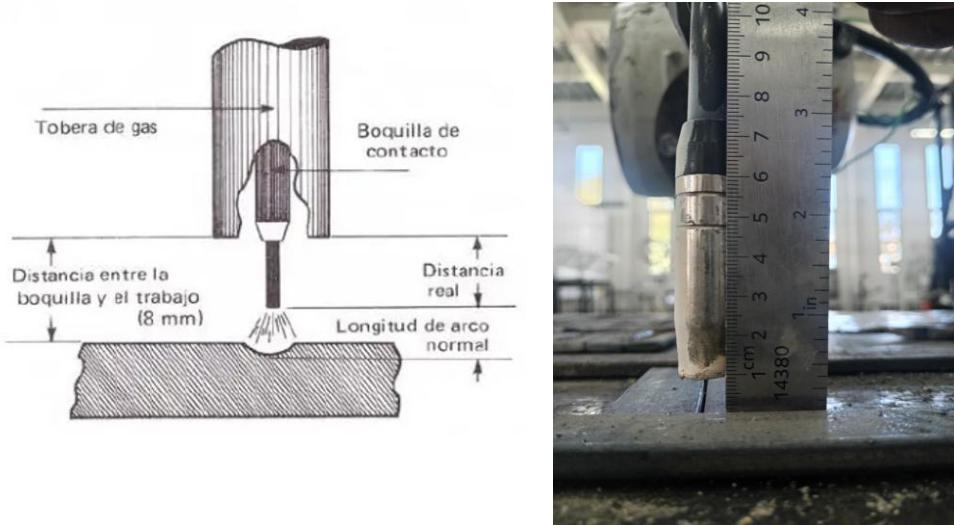


Figura 25 Recomendación de distancia de boquilla tomados de curso de capacitación en soldadura (2.^a ed.) de Gaxiola Maya, editorial LIMUSA. [Pág. 142].

Durante las primeras fases de ensayo, se recomienda mantener fija la posición del robot para evitar problemas de redundancia o sobrecarga de grados de libertad, permitiendo que la variabilidad del proceso se enfoque exclusivamente en los patrones de caligrafía programados. En cuanto a la preparación de las piezas, estas fueron colocadas sobre una plantilla móvil anclada a una mesa metálica, lo cual permitió una rápida colocación, alineación y repetibilidad entre pruebas. Esta plantilla, previamente descrita, fue creada para sujetar firmemente las soleras metálicas y evitar cualquier desplazamiento que pudiera alterar la trayectoria del cordón durante el proceso de soldadura.

Desde el punto de vista operativo, se tomaron diversas precauciones para garantizar buenas condiciones de trabajo. En primer lugar, se aseguró la perpendicularidad de la antorcha respecto a la pieza y se mantuvo constante su inclinación a lo largo de las pruebas, evitando así desviaciones en la geometría del cordón. Previo al encendido del sistema de soldadura, se verificó el estado del cableado, la alimentación eléctrica y las conexiones a tierra, ya que cualquier falla en estos elementos podría generar cortocircuitos, arcos inestables o riesgos eléctricos que comprometan tanto la calidad del proceso como la seguridad del operador. También se revisó el voltaje en vacío del equipo, comparándolo con los valores indicados por el fabricante, con el objetivo de asegurarse de que la máquina no presentara fallas internas o desequilibrios eléctricos que afectaran el rendimiento durante la soldadura (ver figura 26).



Figura 26 Medición de voltaje en vacío

La alimentación del micro alambre se comprobó manualmente activando el sistema de control de avance (perilla del equipo o pulsador de la antorcha), y observando que el alambre fluyera de manera continua a través de la manguera de conducción hasta salir por la boquilla. Un suministro irregular de alambre puede causar interrupciones en la fusión o formación de cordones defectuosos. Y finalmente, se estableció como obligatorio el uso de equipo de protección personal. Adicionalmente, conforme a las recomendaciones del curso de Gaxiola Maya (2012, pp. 92-95), cuando se trabaja con materiales metálicos cuyo espesor supera los 5 mm, se debe realizar un preparado de junta tipo bisel o chaflán, con el fin de asegurar una adecuada penetración del material fundido.

3.1.4 Etiquetado

Dado que el presente trabajo considera múltiples combinaciones de parámetros de proceso, se desarrolló un sistema de nomenclatura estandarizado que permite identificar de forma clara y rápida las condiciones bajo las cuales fue fabricado cada cordón. Este etiquetado está compuesto por un código estructurado del tipo:

XX_Vv_Va_Vr

Donde cada componente representa:

XX: Código de caligrafía utilizada (por ejemplo, Cu = Cuadrada, Zz = Zigzag, Ml = Media Luna, Ci = Circular).

Vv: Nivel de voltaje del inversor.

Va: Nivel de velocidad del micro alambre.

Vr: Velocidad de avance del robot.

Los valores correspondientes a cada uno de los niveles de los parámetros fueron clasificados en tres rangos cualitativos: bajo (nivel 2 de perilla), medio (nivel 5 de perilla) y alto (nivel 8 de perilla). Esta escala fue definida con base en los valores del potenciómetro de la máquina de soldadura VOL-MIG110 y en las observaciones realizadas durante las pruebas. Es importante señalar que estos niveles no corresponden directamente a valores absolutos de voltaje o corriente predeterminados por el fabricante, sino que se derivan de la numeración visible en el panel del equipo. Por esta razón, se sugiere que cualquier replicación del experimento sea precedida por una medición del voltaje en vacío en cada nivel de perilla para asegurar una correspondencia proporcional entre los niveles establecidos y los valores reales del equipo utilizado.

Además del voltaje, se definieron también niveles de velocidad tanto para el micro alambre como para el avance del robot. Ambos parámetros fueron ajustados mediante controles manuales, ya que el sistema no cuenta con retroalimentación digital o sensores integrados. Para estandarizar estos valores, se establecieron tres niveles representativos que permiten su comparación y repetición en diferentes pruebas. En el caso de la velocidad de avance del robot, se consideraron dos niveles: un nivel bajo correspondiente a 5 mm/s y un nivel alto de 10 mm/s. Por otro lado, la velocidad del micro alambre fue controlada a través de la perilla del equipo de soldadura y clasificada en tres niveles: bajo (posición 2), medio (posición 5) y alto (posición 8). Estos rangos fueron determinados empíricamente con base en la observación del proceso y la estabilidad del arco, permitiendo definir configuraciones operativas consistentes para cada caligrafía evaluada. En el caso de la velocidad del micro alambre, los niveles también se determinaron mediante la perilla del equipo, de modo similar al voltaje.

El formato completo de etiquetado tiene como objetivo permitir un análisis sistemático de los efectos que cada combinación de caligrafía, voltaje, velocidad de alimentación y velocidad de desplazamiento del robot tiene sobre la morfología del cordón. Por ejemplo, una muestra etiquetada como:

Cu_2_8_5

Corresponde a una caligrafía cuadrada (Cu), un voltaje bajo (nivel 2), una velocidad alta de micro alambre (nivel 8) y una velocidad baja del robot (5 mm/s). Este tipo de codificación no solo facilita el análisis posterior mediante agrupación y clasificación de imágenes, sino que también mejora la replicabilidad del experimento por otros usuarios, aun si emplean equipos con configuraciones ligeramente diferentes, siempre que puedan ajustar los parámetros en niveles proporcionales.

3.1.4.1 Medición velocidad micro alambre

Para caracterizar la velocidad de alimentación del micro alambre y cuantificar la cantidad de material aportado a diferentes niveles de ajuste, se llevó un procedimiento experimental controlado para obtener medidas repetibles de velocidad lineal (mm/s) y de tasa de alimentación de material o flujo masico (g/s), correlacionadas con los niveles de ajuste de la perilla de velocidad del equipo de soldadura. La medición se debe realizar activando únicamente el sistema de avance de alambre, desconectando la mesa metálica de tierra y verificando que la antorcha no haga contacto con ninguna superficie conductora para evitar daños por ignición accidental evitando riesgos tanto para el operador como para el equipo.

Primero se acciona el gatillo de la antorcha para iniciar el avance del micro alambre, permitiendo la salida libre de material base, cronometrándose simultáneamente en un intervalo fijo de 5 segundos, tiempo durante el cual el alambre avanza de forma continua. Al finalizar el intervalo, se corta el alambre alimentado con herramientas de corte, y se mide la longitud del segmento, para posteriormente pesar en una balanza la masa depositada. Con estas mediciones se puede entonces obtener la velocidad lineal (dividiendo la longitud total alimentada entre el tiempo de cronometraje) y el flujo masico (dividiendo la masa total del segmento cortado entre el mismo intervalo de tiempo). El proceso se repite para cada uno de los niveles disponibles en la perilla de control de velocidad del micro alambre, permitiendo construir una curva de comportamiento velocidad/nivel. En la figura 27 se puede ver el sistema de alimentación de micro alambre.



Figura 27 Sistema de alimentado de micro alambre de maquina VOL-MIG110

3.1.5 Matriz de pruebas

Para asegurar una experimentación estructurada (que normalmente lleva a cabo el ingeniero de procesos) se utiliza una matriz de pruebas que permita visualizar sistemáticamente el efecto de los parámetros asociados: nivel de voltaje del inversor, velocidad de alimentación del micro alambre y velocidad de avance del robot. Esta matriz funciona como una herramienta de planificación que sirve de soporte para realizar de manera ordenada combinaciones objetivo, permitiendo obtener datos comparables que puedan ser utilizados para ajustes futuros o desarrollo de metodologías propias (ver figura 28).

Como primer paso se selecciona una velocidad de avance constante para la antorcha, que (para esta metodología) es equivalente directamente a la velocidad del robot; Se recomienda trabajar exclusivamente con velocidades de 5 mm/s o 10 mm/s, ya que velocidades superiores pueden hacer difícil mantener un cordón continuo y uniforme debido a las limitaciones del suministro de micro alambre y de la estabilidad del arco. Al fijar esta variable, se logra aislar el impacto de los cambios de voltaje y de velocidad de micro alambre sobre la calidad de los cordones, sin la interferencia adicional provocada por variaciones en el desplazamiento del robot.

Una vez establecida la velocidad de avance, se procede a recorrer las combinaciones de voltaje y velocidad de micro alambre. Para cada nivel fijo de velocidad de micro alambre —bajo (nivel 2), medio (nivel 5) o alto (nivel 8)— se prueban todos los niveles de voltaje en orden (bajo, medio y alto). Después de completar este barrido de voltajes en un nivel de micro alambre, se incrementa el nivel de velocidad del micro alambre al siguiente escalón y se repite el procedimiento. Al concluir todas las combinaciones para una velocidad de micro

alambre, y si así se requiere, se aumenta la velocidad de avance del robot y se inicia nuevamente el ciclo completo de combinaciones.

Cada prueba se identifica mediante un código único que sigue el formato XX_V_M_A, donde se reflejan de manera resumida las condiciones de soldadura utilizadas.

ID prueba	Caligrafía	Nivel de voltaje de inversor (bajo, medio, alto)	Velocidad de micro alambre (bajo, medio, alto)	Velocidad de avance (mm/s)

Figura 28 Representación gráfica de la estructura de la matriz de pruebas de soldadura.

Por ejemplo, al trabajar en la sección de velocidad de avance de 5 mm/s, primero se colocan todas las combinaciones de caligrafía, voltaje y micro alambre a esa velocidad fija. Posteriormente, una vez agotadas esas combinaciones, se pasa a la velocidad de 10 mm/s y se repite el mismo orden. De este modo, una prueba etiquetada como Cu_2_2_5 indicaría una soldadura con caligrafía cuadrada, voltaje bajo, micro alambre a velocidad baja y avance de 5 mm/s; mientras que un cambio a Cu_2_5_5 representaría únicamente el incremento de la velocidad del micro alambre, manteniendo constantes las demás condiciones.

3.2 Adquisición de imágenes

Se deben de capturar en imagen los cordones de soldadura generados en los ensayos para el posterior entrenamiento del modelo de clasificación. En esta etapa se debe generar un conjunto de imágenes lo suficientemente variado que refleje las características reales de los cordones, evitando sesgos por iluminación, posición o perspectiva. Se recomienda utilizar cámaras o dispositivos móviles con una resolución de al menos 2 megapíxeles, debido a su disponibilidad generalizada de equipos de bajo costo capaces de cumplir con dicho requisito, lo que facilita la replicabilidad de la metodología incluso en entornos con recursos limitados.

Para la captura de imágenes no se utilizan sistemas de iluminación artificial especializados, se puede realizar bajo luz natural, aunque siempre debe de procurarse que la escena esté iluminada de manera uniforme para evitar zonas de sombra intensa o sobreexposición que puedan afectar el procesamiento posterior de las imágenes. Sin

embargo, en caso de ser necesario, se puede utilizar luz difusa natural o lámparas de luz blanca fría para homogenizar la iluminación.

Durante la captura, se mantiene una distancia aproximada de 10 cm entre la cámara y el cordón de soldadura. A esta distancia se obtienen aun detalles del cordón, sin distorsiones ópticas significativas. Se debe verificar que el enfoque esté correctamente ajustado y que toda la extensión del cordón permanezca nítida en la imagen; Para cada cordón, se realiza la captura de imágenes desde tres ángulos diferentes: un ángulo superior (cenital), un ángulo ligeramente inclinado a la izquierda y otro a la derecha, tal como se ilustra en la figura 29. Esta estrategia busca introducir variabilidad en el data set, funcionando como un método de "data augmentation" real, al permitir que el modelo de clasificación aprenda las características del cordón bajo diferentes perspectivas de observación.

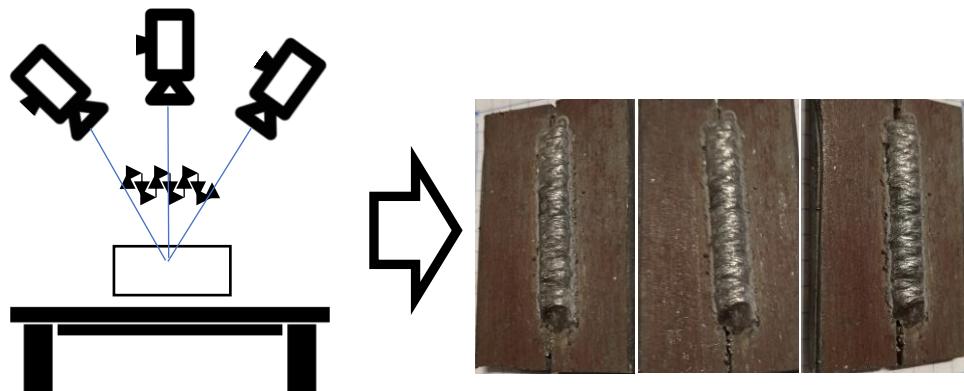


Figura 29 Diagrama explicativo captura de imágenes.

Adicionalmente, es importante considerar algunos factores que mejoran la calidad de las imágenes capturadas como el evitar reflejos directos que alteren la percepción de las características del cordón. Para reducirlos, se puede inclinar ligeramente la cámara o modificar la posición respecto a la fuente de luz. Se recomienda colocar los cordones sobre un fondo (neutro) de color uniforme y mate de ser posible. Es recomendable también utilizar un trípode o soporte improvisado puede mejorar la estabilidad de la cámara y evitar imágenes borrosas. Finalmente, si el equipo lo permite, hay que ajustar manualmente la exposición para asegurar que los detalles del cordón no se pierdan ni por exceso de brillo ni por zonas oscuras.

3.3 Preprocesamiento de imágenes

Tras la adquisición de las imágenes de los cordones de soldadura, se procede a su preprocesamiento para estandarizar las condiciones de entrada al modelo de clasificación, se recomienda asegurar que todas las imágenes que alimentan la red neuronal comparten características homogéneas en cuanto a tamaño, escala de intensidad y condiciones de iluminación. El flujo de procesamiento aplicado a cada imagen capturada comprende en primer lugar, una corrección de orientación automática, asegurando que todos los cordones estén alineados de manera consistente en las imágenes, con el eje principal del cordón en posición vertical para facilitar el análisis posterior reduciendo la variabilidad asociada a la posición angular. Posteriormente, se lleva a cabo un redimensionamiento de las imágenes a una resolución fija, se recomienda una resolución de 100 píxeles de altura por 160 píxeles de ancho, manteniendo una proporción de aspecto de 1:1.6.

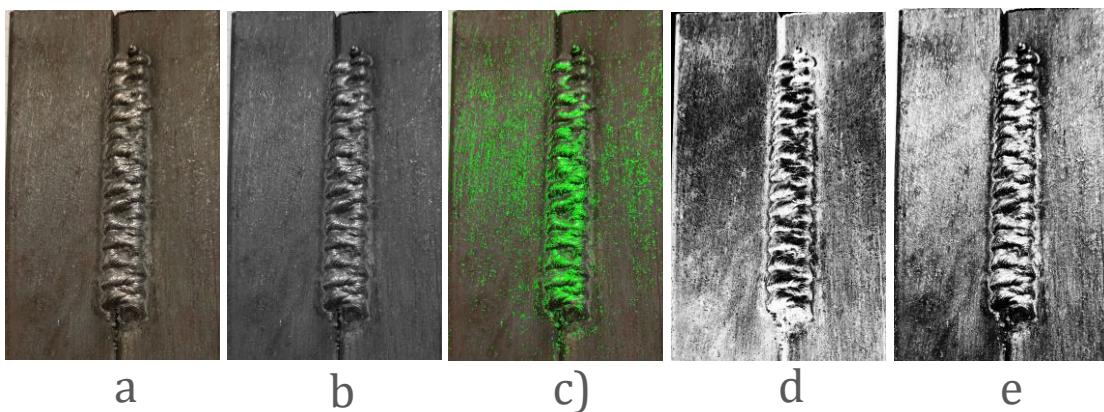


Figura 30 Ejemplo de procesamientos a) original b) conversión a gris c) detección de contornos d) negativo e) ecualización de histograma

A continuación, se realiza la conversión a escala de grises. Esta transformación reduce las imágenes de tres canales (RGB) a un único canal de intensidad, eliminando redundancia de información de color irrelevante, la imagen resultante codifica únicamente la variación de luminancia, que es altamente correlacionada con las características de superficie del cordón. El siguiente paso es la normalización de los valores de intensidad. Cada píxel de la imagen en escala de grises es transformado para que su rango de valores se sitúe entre 0 y 1 (o en algunos casos, entre -1 y 1, dependiendo del modelo final a utilizar); y finalmente, se aplica una ecualización de histograma, que redistribuye los niveles de intensidad de la imagen de modo que se aproveche de manera más uniforme todo el rango dinámico disponible para

facilitar la detección de bordes, texturas y detalles sutiles. La figura 30 ilustra algunos ejemplos de procesamiento de imágenes.

3.4 Propuesta de arquitectura de CNN y entrenamiento

Se establece una estrategia que abarca la preparación de datos, la definición de la arquitectura base y el ajuste progresivo de hiperparámetros. Como primer paso, se debe asegurar que las imágenes utilizadas hayan pasado por las etapas de procesamiento previamente descritas: corrección de orientación, redimensionamiento, conversión a escala de grises, normalización y ecualización de histograma para homogenizar las condiciones de entrada y facilitar la eficiencia del aprendizaje del modelo.

Las imágenes preprocesadas se organizan en una estructura de carpetas jerárquica, donde cada subcarpeta representa una de las clases de caligrafía a identificar (en este caso: cuadrada, zigzag, circular, media luna). Esta organización facilita el manejo de los datos por parte de librerías de entrenamiento que emplean cargas automáticas basadas en las etiquetas de carpeta. Se recomienda mantener un número equilibrado de muestras por clase para evitar sesgos durante el entrenamiento. En cuanto al diseño de la red, se parte de una arquitectura básica basada en la combinación de capas de convolución, capas de agrupamiento (pooling) y capas densas finales. La primera capa de convolución puede configurarse con 32 o 64 filtros de tamaño 3x3, seguidos por operaciones de activación ReLU. Conforme se avanza en profundidad dentro de la red, se sugiere duplicar progresivamente el número de filtros (64-128-256) para permitir la captura de características de mayor complejidad.

Para todas las capas convolucionales, se emplea la función de activación ReLU debido a su eficiencia y capacidad para acelerar el aprendizaje. La reducción espacial de las dimensiones se realiza mediante capas de max pooling 2x2, que ayudan a consolidar las características relevantes y reducir la carga computacional. El entrenamiento de la red se lleva a cabo bajo un esquema supervisado, utilizando las imágenes etiquetadas previamente. El número de épocas recomendado varía entre 30 y 100, dependiendo de la convergencia observada en las primeras ejecuciones. Un valor inicial sugerido para el tamaño de lote (batch size) es 16 o 32, dependiendo de la capacidad de procesamiento disponible, buscando un balance entre estabilidad de gradientes y velocidad de entrenamiento.

La optimización del modelo se realiza preferentemente utilizando el optimizador Adam, con una tasa de aprendizaje inicial de 0.001. Esta tasa puede ajustarse posteriormente si se observa que la curva de pérdida se estabiliza o presenta oscilaciones no deseadas. Con el fin de evitar el sobreajuste, se introduce regularización mediante capas de dropout ubicadas antes de la capa densa final, empleando tasas de abandono (dropout rate) entre 0.2 y 0.5 según la necesidad observada durante las pruebas preliminares.

3.4.1 Preparación de los datos de entrada

Una vez preprocesadas y organizadas las imágenes en carpetas según su clase correspondiente, se procede a preparar los datos de entrada para el entrenamiento de la red neuronal convolucional (CNN) para asegurar que el modelo reciba información adecuada durante el proceso de aprendizaje.

El primer paso consiste en construir un objeto de tipo data generator o data loader. Este objeto se configura para leer automáticamente las imágenes desde las carpetas, asignando como etiqueta de clase el nombre de la subcarpeta donde se encuentra cada imagen. Se recomienda dividir el conjunto total de datos en tres subconjuntos principales: conjunto de entrenamiento (60% de las imágenes), conjunto de validación (20% de las imágenes a esta partición) y conjunto de prueba (20% restante de las imágenes). Esta partición debe realizarse de forma aleatoria para asegurar que cada subconjunto contenga una representación equilibrada de todas las clases presentes.

Durante la carga de datos, se aplica una normalización automática a los valores de los píxeles, escalándolos a un rango de [0,1] mediante la división entre 255. Esta práctica facilita la convergencia del modelo al mantener los datos de entrada en una escala numérica apropiada para los algoritmos de retro propagación de error. Adicionalmente, puede configurarse el “data loader” para realizar operaciones básicas de aumento de datos (data augmentation) como rotaciones pequeñas, desplazamientos horizontales o variaciones de brillo, si se desea aumentar la robustez del modelo. Finalmente, se establecen las dimensiones de entrada esperadas para la red, asegurándose de que cada imagen tenga un tamaño uniforme, tal como se definió previamente (por ejemplo, 100x160 píxeles en escala de grises).

3.4.2 Arquitectura base propuesta

Se estructura bajo un esquema modular compuesto por bloques de convolución seguidos de operaciones de reducción de dimensionalidad (pooling), capas de regularización para evitar el sobreajuste y finalmente capas densas encargadas de realizar la clasificación.

3.4.2.1 Capa de entrada (input layer):

Se configura para recibir imágenes de tamaño fijo (por ejemplo, 100x160 píxeles en escala de grises). En esta capa se define explícitamente la forma de los datos que ingresarán a la red.

3.4.2.2 Bloques de convolución y pooling:

Se aplica una primera operación de convolución utilizando filtros (por ejemplo, 32 filtros de tamaño 3x3) para detectar características locales como bordes y texturas. Posteriormente, se realiza una activación ReLU (Rectified Linear Unit) para introducir no linealidad en el modelo y acelerar la convergencia. Se emplea una operación de max pooling (típicamente 2x2) para reducir la dimensionalidad espacial, consolidar las características más relevantes y disminuir el riesgo de sobreajuste. Se considera un segundo y tercer bloque de convolución y pooling dependiendo de los resultados preliminares). Se repite el patrón anterior, incrementando el número de filtros (64 y 128, respectivamente) en cada bloque posterior para capturar patrones de mayor abstracción.

3.4.2.3 Capa de aplanamiento (flatten layer):

Se convierte la matriz tridimensional de características resultante en un vector unidimensional para conectar con las capas densas.

3.4.2.4 Capa densa oculta (hidden dense layer):

Se introduce una o más capas totalmente conectadas (por ejemplo, 128 o 256 neuronas) con activación ReLU, que permiten la combinación de características extraídas para realizar inferencias de alto nivel.

3.4.2.5 Capa de regularización (dropout):

Se incorpora una capa de dropout con una tasa de abandono entre 0.2 y 0.5 para prevenir el sobreajuste, desactivando aleatoriamente un porcentaje de neuronas durante el entrenamiento.

3.4.2.6 Capa de salida (output layer):

Finalmente, se añade una capa densa con tantas neuronas como clases existan (en este caso, cuatro: cuadrada, zigzag, circular, media luna), utilizando la función de activación softmax para obtener probabilidades normalizadas de clasificación por cada clase.

3.5 Validación

Una vez entrenado el modelo de red neuronal convolucional, se procede con la etapa de validación para evaluar el desempeño del sistema de clasificación propuesto. Esta evaluación se realiza utilizando un conjunto de imágenes previamente separado para comprobar su capacidad de generalización ante nuevas muestras.

El conjunto de validación se compone típicamente del 20% de las imágenes totales y se utiliza para calcular las métricas clave del modelo. Las métricas seleccionadas incluyen: exactitud global (accuracy), que refleja el porcentaje de clasificaciones correctas en el total de muestras; precisión (precision), que indica el grado de acierto del modelo cuando predice una clase específica; recuperación o exhaustividad (recall), que mide la capacidad del modelo para identificar correctamente todos los elementos pertenecientes a una clase; y F1-score, que representa un equilibrio entre precisión y recall. Además, se implementa una matriz de confusión, que permite visualizar las predicciones correctas e incorrectas por clase, facilitando la interpretación del comportamiento del clasificador.

Para esta investigación, se establece como criterio deseable que el modelo alcance al menos un 90% de exactitud (accuracy) en el conjunto de validación, considerando esta cifra como punto de referencia basado en trabajos previos reportados en la literatura en clasificación de imágenes de soldadura con redes neuronales.

3.6 Desarrollo de software

Como parte de la implementación del sistema de clasificación automática, se diseña una interfaz gráfica de usuario (GUI) utilizando MATLAB, enfocada en la clasificación visual y rápida de cordones de soldadura tipo MIG. Esta herramienta está pensada para ser utilizada tanto en laboratorios de formación como en entornos industriales, permitiendo que personal técnico sin conocimientos avanzados en programación pueda validar resultados mediante una operación intuitiva y accesible.

El diseño de la interfaz se organiza mediante un layout, para facilitar su comprensión y operatividad. Incluye la colocación de logotipos institucionales en la parte superior izquierda y derecha, que permiten identificar claramente el entorno académico o corporativo en el que se utiliza la aplicación. Al centro se encuentra un título que comunica de manera directa la función del sistema, complementado por un área de imagen ilustrativa que muestra visualmente el patrón de caligrafía objetivo seleccionado. Justo debajo, un menú desplegable permite al usuario seleccionar la caligrafía esperada entre las opciones disponibles (cuadrada, zigzag, circular o media luna), estableciendo así el criterio de validación para los archivos a analizar.

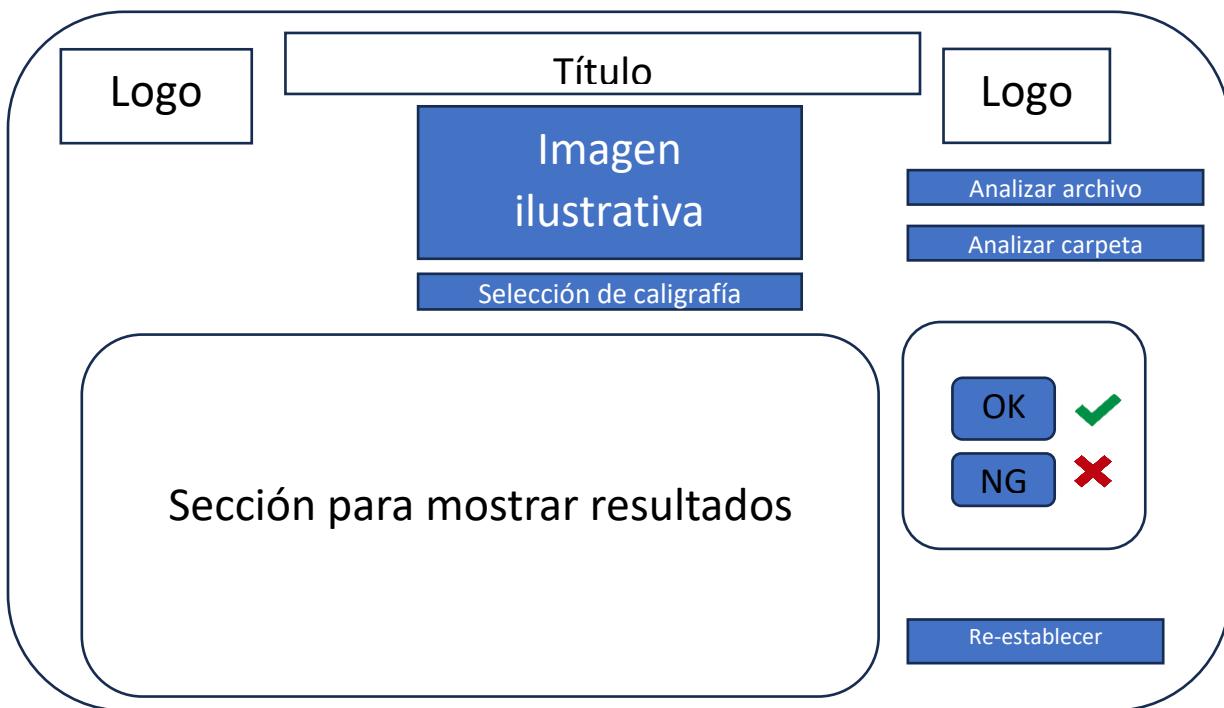


Figura 31 Layout Interfaz WeldingNet

El Layout de la interfaz se puede observar en la figura 31 en la que se aprecia que debe contar con botones específicos para analizar imágenes de forma individual o por lotes (carpetas completas), activando así la clasificación automática con base en el modelo previamente entrenado. Los resultados del análisis se presentan en una tabla de resultados que muestra, en tiempo real, los nombres de los archivos procesados junto con la clase predicha por el modelo de red neuronal convolucional cargado. Además, se integran indicadores visuales de conteo para mostrar de forma clara cuántas imágenes han sido

clasificadas como OK (coincidencia con la clase esperada) o NG (no coincidencia), proporcionando una verificación rápida y efectiva en piso.

Para mejorar la usabilidad, se incluye un botón de restablecer que permite limpiar la información visualizada en pantalla y comenzar una nueva sesión de análisis sin necesidad de reiniciar la aplicación. Todo el sistema se apoya en la carga automatizada de un archivo con extensión “.mat” que contiene el modelo previamente entrenado, el cual se activa automáticamente al iniciar el análisis. Las imágenes procesadas pasan por las etapas previas de preprocesamiento (incluyendo redimensionamiento a proporción 1:1.6, escala de grises, ecualización de histograma y normalización), asegurando así la compatibilidad con la interfaz. Esta interfaz acelera el proceso de validación de cordones tanto para el ingeniero de procesos al momento de programar una trayectoria, como al ingeniero de calidad como verificación rápida del trabajo realizado, y elimina gran parte de la subjetividad humana asociada a la inspección manual. Su estructura de manera modular también permite futuras extensiones, como la integración de nuevas métricas de desempeño, sugerencias de corrección o filtros orientados a condiciones específicas del proceso de soldadura.

Capítulo 4

Experimentación y

Resultados

En esta etapa experimental se replica y valida de forma práctica la metodología propuesta en el capítulo anterior para la clasificación automática de caligrafías de cordones de soldadura tipo MIG-FCAW mediante una red neuronal convolucional (CNN), denominada WeldingNet. La experimentación se realiza utilizando equipo y materiales accesibles, siguiendo un enfoque que pueda ser replicado fácilmente en talleres, laboratorios académicos e incluso en pequeñas empresas con recursos limitados. Para lograrlo, la experimentación considera todas las etapas necesarias para el proceso integral: preparación del equipo robótico, configuración de parámetros experimentales, adquisición y preprocesamiento de imágenes, entrenamiento y evaluación de la CNN, así como la implementación y validación del software de clasificación en una interfaz gráfica.

4.1 Configuración experimental

4.1.1 Equipamiento utilizado

Para llevar a cabo la experimentación se utiliza el equipamiento disponible en el laboratorio CETEVI, ubicado en el Campus Centro Universitario (CU) de la Universidad Autónoma de Querétaro (UAQ). El sistema robótico empleado es un robot industrial ABB IRB-1410 con seis grados de libertad. El robot es controlado mediante un controlador ABB IRC5 M2004, que permite una programación intuitiva mediante lenguaje RAPID y cuenta con interfaz gráfica en el FlexPendant para operación y monitoreo. Este sistema fue configurado y operado dentro de los rangos recomendados por el fabricante, garantizando movimientos precisos y repetibles en cada ejecución.

Como equipo de soldadura se emplea una máquina soldadora de micro alambre modelo VOL-MIG110, de tipo FCAW (Flux-Cored Arc Welding), destacando por no requerir suministro externo de gas protector gracias a su núcleo fundente. La soldadora opera con alimentación eléctrica estándar de 127 V a 60 Hz y cuenta con perillas analógicas para ajustar manualmente la intensidad de corriente y voltaje, referenciadas con una escala proporcional de niveles del 1 al 9. Aunque no se dispone de una medición precisa digitalizada, se utiliza una configuración relativa (bajo nivel 2, medio nivel 5, alto nivel 8) que permite estandarizar condiciones experimentales repetibles.

4.1.2 Programación y ejecución de trayectorias robóticas

La programación del robot se realiza mediante el lenguaje RAPID utilizando el software RobotStudio de ABB. Este software permite diseñar, simular y verificar

visualmente las trayectorias del robot antes de ser implementadas físicamente. Para transferir las trayectorias al robot se utilizan las siguientes etapas generales: primero, se definen claramente las variables necesarias para cada tipo de trayectoria: ancho total del patrón (A), longitud total del cordón (L) y distancia de avance por paso (P). Posteriormente, utilizando el pseudocódigo previamente presentado en la metodología, se generan coordenadas específicas y secuencias de movimientos (MoveL para desplazamientos lineales y MoveC para trayectorias circulares) adaptadas a cada patrón específico de caligrafía: cuadrada, zigzag, circular y media luna.

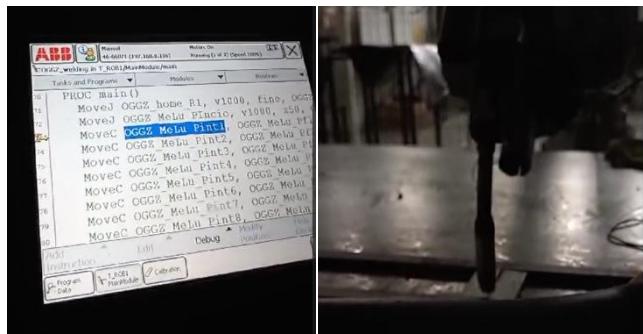


Figura 32 Ejemplo ejecución rutina robot ABB

Una vez generadas las trayectorias en RobotStudio, estas se simulan para verificar que no existan colisiones o interferencias potenciales. Tras la validación simulada, las trayectorias se exportan al controlador ABB IRC5 y se cargan manualmente mediante el FlexPendant. El operador verifica manualmente la posición inicial del robot y ajusta mínimamente la posición del TCP y la distancia de la antorcha si es necesario. Finalmente, se ejecutan los programas, observando en tiempo real el comportamiento del robot, realizando ajustes menores si se detectan desviaciones durante la operación inicial (ver figura 32).

4.1.2.1 Programación de trayectoria cuadrada

El pseudocódigo para la implementación de la trayectoria cuadrada se presenta en la tabla 1:

Psudocódigo trayectoria cuadrada

Inicialización:

Posición inicial = centro de la unión

Desplazar hacia anchura positiva A/2 (MoveL)

Bucle Principal (Iteraciones):

Para i desde 1 hasta N hacer:

MoveL en dirección largo positivo, distancia = P
MoveL en dirección anchura negativa, distancia = A
MoveL en dirección largo positivo, distancia = P
MoveL en dirección anchura negativa, distancia = A

Fin ciclo // cierre del patrón

Si N es par:

MoveL en dirección anchura negativa, distancia = A/2

Si N es impar:

MoveL en dirección anchura positiva, distancia = A/2

Fin

Fin del Algoritmo

Tabla 1 Pseudocódigo trayectoria cuadrada

El patrón cuadrado comienza desde el centro de la junta, realizando un pequeño desplazamiento lateral de $A/2$ hacia la derecha o hacia el eje positivo del plano Y, dependiendo del marco de referencia del robot. Este ajuste inicial permite que el primer movimiento de avance inicie desde una posición equilibrada en relación con el ancho total del patrón. En cuanto a la orientación del cordón, en este trabajo se definió una dirección de avance sobre el eje X, con desplazamientos laterales en el eje "y". No obstante, esta lógica puede adaptarse fácilmente a otras disposiciones, por ejemplo, para realizar cordones verticales o sobre superficies inclinadas.

Cuando el número de ciclos N es impar, la trayectoria concluye en un punto desplazado lateralmente respecto al eje central. Para compensar esta desviación, se incluye una corrección final equivalente a $A/2$ en dirección opuesta al desplazamiento inicial, de forma que el patrón cierre exactamente sobre el eje de la unión y mantenga la simetría visual. Todos los movimientos de la trayectoria fueron implementados empleando instrucciones del tipo MoveL, ya que el patrón está compuesto únicamente por líneas rectas y no requiere interpolación circular ni curvas suavizadas. Esta caligrafía, por su geometría definida y su acumulación puntual de material en los vértices, es particularmente útil en la evaluación térmica del cordón, así como en la detección de defectos generados por sobrecalentamiento o posibles discontinuidades derivadas de cambios bruscos de dirección.

4.1.2.2 Programación de trayectoria zigzag

El pseudocódigo para la implementación de la trayectoria zigzag se presenta en la tabla 2:

Pseudocódigo trayectoria zigzag

Inicialización:

Posición inicial = centro de la unión

Desplazar en X (largo) paso/2 y en Y (anchura) negativo A/2 (MoveL)

Bucle Principal (Iteraciones):

Para i desde 1 hasta N hacer:

MoveL en dirección largo positivo + paso y anchura positiva +A

MoveL en dirección largo positivo + paso y anchura negativa -A

Fin ciclo // Cierre del patrón

Si N es par:

MoveL en largo + paso y anchura -A

Si N es impar:

MoveL en largo + paso y anchura +A

Fin

Fin del Algoritmo

Tabla 2 Pseudocódigo trayectoria zigzag

Este patrón inicia en el centro de la junta con un desplazamiento de ajuste hacia el lado negativo del eje Y en una distancia equivalente a A/2, y un avance parcial en X de P/2. Este punto de partida asegura simetría inicial en la trayectoria y mantiene el cordón centrado respecto a la pieza.

Cada ciclo implica un avance en X de un paso completo acompañado por un desvío en Y alternante: primero hacia el lado positivo (derecha) y luego hacia el lado negativo (izquierda), conformando un trazo en forma de "V". Este patrón se repite hasta alcanzar el número total de ciclos N.

En caso de que N sea impar, el patrón concluye con un trazo que lo desbalancea ligeramente respecto al eje de simetría, por lo que se aplica una corrección final equivalente a un paso P y un desplazamiento lateral A en la misma dirección del último trazo para mantener la uniformidad visual del cordón.

4.1.2.3 Programación de trayectoria semicircular

El pseudocódigo para la implementación de la trayectoria semicircular se presenta en la tabla 3:

Pseudocódigo trayectoria semicircular (medialuna)

Inicialización:

Posición inicial = orilla izquierda de la junta sobre la línea de inicio

Bucle Principal (Iteraciones):

Para i desde 1 hasta N hacer:

Si i es impar entonces: // curva hacia arriba

Punto intermedio:

largo = largo anterior - (P/2) + P/(2*D)

ancho = ancho anterior + (A/2) + A/(2*D)

Punto final:

largo = largo anterior - P

ancho = ancho anterior + A

Ejecutar MoveC a través del punto intermedio hasta punto final

Si i es par entonces: // curva hacia abajo

Punto intermedio:

largo = largo anterior - (P/2) + P/(2*D)

ancho = ancho anterior - (A/2) - A/(2*D)

Punto final:

largo = largo anterior - P

ancho = ancho anterior - A

Ejecutar MoveC a través del punto intermedio hasta punto final

Fin del Algoritmo

Tabla 3 Pseudocódigo trayectoria semicircular (medialuna)

El patrón comienza en el extremo izquierdo del cordón, en la intersección entre el borde de la pieza y el eje longitudinal de la unión. A diferencia de otras caligrafías que comienzan en el centro, la media luna inicia en un extremo y avanza en pasos sucesivos a lo largo del eje X. En cada iteración i , se determina si se trata de un ciclo impar o par. Si el ciclo es impar, la trayectoria describe una curva ascendente (hacia el eje positivo del plano Y), mientras que, si es par, la curva se realiza hacia abajo (eje negativo del plano Y). El desplazamiento curvo se ejecuta mediante instrucciones MoveC, que permiten interpolar un

arco circular entre tres puntos: el punto actual, un punto intermedio que define la curvatura, y un punto final que marca el avance del paso completo.

El parámetro diámetro (D) controla la curvatura de la trayectoria. Una mayor cantidad de pasos por diámetro genera curvas más suaves, mientras que una menor relación provoca trayectorias más cerradas o abruptas. Esta lógica puede ser adaptada para cualquier orientación del plano de trabajo (horizontal, vertical o sobre cabeza), y es particularmente útil para simular trayectorias en soldadura de recubrimiento o reparación, donde se requiere atención especial en los bordes del material fundido.

4.1.2.4 Programación de trayectoria circular

El pseudocódigo para la implementación de la trayectoria circular se presenta en la tabla 4:

Pseudocódigo trayectoria circular

Inicialización:

Posición inicial = orilla izquierda de la junta, sobre la línea de inicio

Bucle Principal (Iteraciones):

Para i desde 1 hasta N hacer:

// Movimiento circular 1 (cuarto de círculo hacia abajo)

Punto intermedio:

largo = largo anterior – (A / 2)

ancho = ancho anterior – (A / 2)

Punto final:

largo = largo anterior – A

ancho = ancho anterior

Ejecutar MoveC hacia abajo

// Movimiento circular 2 (cuarto de círculo hacia arriba)

Punto intermedio:

largo = mismo largo del punto intermedio anterior

ancho = ancho del punto intermedio anterior + A

Punto final:

largo = largo original de la iteración (misma base de paso)

ancho = ancho anterior

Ejecutar MoveC hacia arriba

// Movimiento recto para avanzar a la siguiente iteración

Punto final:

largo = largo anterior – P

ancho = mismo ancho

Ejecutar MoveL
Fin del Algoritmo

Tabla 4 Pseudocódigo trayectoria circular

El patrón circular se genera a partir del extremo izquierdo del cordón, avanzando paso a paso mediante movimientos curvos interpolados por instrucciones MoveC. La estructura de cada ciclo consta de dos semicírculos consecutivos: el primero descendente (hacia el eje negativo del plano Y) y el segundo ascendente (hacia el eje positivo), formando así un lazo cerrado completo por cada paso recorrido. Cada iteración se define por tres segmentos: dos curvas circulares y un desplazamiento recto que permite continuar la trayectoria. El tamaño del círculo generado está definido por el parámetro A, correspondiente al ancho total de oscilación del electrodo. El paso P determina la distancia de avance a lo largo del eje longitudinal del cordón entre cada ciclo circular.

En la implementación se utiliza siempre como base de referencia el punto final de la iteración anterior, asegurando continuidad y cohesión geométrica. Las instrucciones MoveC se seleccionan debido a su capacidad de interpolar trayectorias curvilíneas suaves, ideales para simular el movimiento circular continuo del electrodo en trayectorias reales de soldadura tipo MIG-FCAW. Este patrón resulta particularmente útil en prácticas orientadas a la evaluación térmica y geométrica del cordón ante oscilaciones amplias, además de ser aplicable en zonas donde se requiere alta uniformidad en la distribución del material de aporte.

4.1.3 Herramental sugerido y condiciones operativas reales

Debido a la necesidad de mantener una referencia constante y repetible para la posición de la antorcha de soldadura, se optó por un soporte genérico, emulando una estructura comúnmente utilizada en aplicaciones industriales de soldadura. Este soporte adapta la antorcha comercial por medio de ajuste manual por medio de una abrazadera, permitiendo ajustes menores en posición y orientación, garantizando la coincidencia entre el punto central de la herramienta (Tool Center Point, TCP) del robot y el punto medio de la boquilla de soldadura. El herramiental del soporte (mostrado en la figura 33) permite ligeras adaptaciones o correcciones posteriores a colisiones menores durante pruebas iniciales,

aunque exige una revisión periódica para asegurar su posición correcta debido a que no es un soporte totalmente rígido.



Figura 33 Herramental utilizado en TCP

La mesa de trabajo fue construida específicamente para estas pruebas, utilizando dos soleras largas como guías laterales que sujetan firmemente los especímenes metálicos cortados previamente en tramos estándar de 8 cm. Las piezas se colocan y aseguran mediante prensas ajustables, lo que facilita su extracción y colocación rápida sin necesidad de reajustes significativos. Esta mesa también permite ligeros ajustes de posición para evitar interferencias o colisiones no deseadas en caso de desvíos menores en las trayectorias programadas del robot. En términos de seguridad operativa, se recomienda que antes de iniciar cualquier prueba de soldadura se realicen verificaciones visuales y físicas del equipo eléctrico (verificar estado del cableado, conexiones a tierra y nivel de voltaje en vacío), así como asegurar la correcta alimentación del micro alambre mediante pruebas previas sin contacto eléctrico con la mesa metálica, para evitar riesgos de cortocircuito o accidentes eléctricos. Es obligatorio utilizar equipo de protección personal durante todas las etapas de operación, incluyendo careta protectora, guantes especiales, ropa ignífuga y protección auditiva, siguiendo estrictamente las recomendaciones de seguridad industrial.

La distancia de trabajo entre la boquilla de soldadura y la superficie de la pieza sirve para asegurar estabilidad en el proceso. Esta distancia se mantuvo entre 8 mm y 9 mm, ya que en pruebas preliminares se identificó que distancias superiores a 10 mm provocan la interrupción del arco eléctrico con la generación de un flamazo, como se muestra en la figura 34. Por el contrario, distancias menores a 8 mm generan riesgo de colisión con el material depositado, obstruyendo la salida del micro alambre.



Figura 34 Distancia recomendada y consecuencia de no seguirla

4.2 Materiales y condiciones de prueba

Para realizar las pruebas experimentales se utilizaron probetas de soleras de acero al carbón. El material base consistió en dos soleras de acero al carbón con un espesor de 6 mm cada una, ancho estándar de una pulgada (25.4 mm), y cortadas en segmentos de longitud uniforme de 8 cm. Estas piezas se prepararon para asegurar condiciones superficiales constantes. Las condiciones medioambientales bajo las cuales se realizaron las pruebas experimentales corresponden a iluminación natural, para inspecciones rápidas o visuales sin iluminación artificial adicional. Durante la ejecución experimental, se llevó a cabo una inspección visual inmediata para asegurar que las imágenes obtenidas reflejaran correctamente las condiciones reales del cordón de soldadura. La captura de las imágenes fue realizada utilizando una cámara digital estándar integrada en un teléfono móvil modelo Honor X8, configurada en modo automático, y posicionada de manera constante con una distancia focal fija de aproximadamente 10 cm entre el lente y la superficie del cordón de soldadura generado.

4.2.1 Tablas de voltaje y obtención según parámetros establecidos

Durante el desarrollo de las pruebas experimentales se realizaron mediciones directas de voltaje y corriente en el equipo de soldadura modelo VOL-MIG110, utilizando un multímetro digital conectado a la salida de la antorcha mientras el equipo se encontraba activo, pero sin carga sobre el material base. Las mediciones fueron parecidas para los tres niveles disponibles en la perilla de ajuste del equipo: bajo, medio y alto, correspondientes a posiciones numéricas aproximadas de 2, 5 y 8 respectivamente.

Los resultados mostraron variaciones mínimas en las lecturas de voltaje y corriente entre cada nivel, con diferencias apenas perceptibles desde el punto de vista eléctrico. Esta aparente falta de variabilidad puede explicarse por la naturaleza del equipo, ya que el modelo VOL-MIG110 es una máquina compacta de tipo inversor que incluye regulaciones internas automáticas, como ajustes dinámicos de inductancia y sistemas de estabilización de arco. Este tipo de regulación tiene como objetivo mantener la estabilidad del proceso, lo que se traduce en valores eléctricos relativamente constantes bajo condiciones de operación en vacío, aunque el comportamiento del arco y la calidad del cordón varían notablemente durante la aplicación práctica sobre el material base.

Debido a estas características, se optó por estimar los valores de operación utilizando como base la información técnica proporcionada por el fabricante en la placa de especificaciones del equipo. A partir de esta placa, y considerando las posiciones relativas de la perilla, se aplicó una interpolación lineal razonada para asignar valores representativos de voltaje y corriente a cada nivel operativo. Se observaron los rangos de operación nominal del sistema: un voltaje de entrada de 110–120 V, y un rango de salida de corriente continua que va aproximadamente de 40 A a 100 A, con un voltaje de salida asociado entre 15 V y 20 V. Aunque el fabricante no especifica explícitamente el voltaje exacto para cada posición de la perilla, se sabe que estas máquinas operan mediante un sistema escalonado de control análogo, donde cada posición de la perilla corresponde a una configuración interna predeterminada que combina ajustes de corriente y voltaje.

Bajo esta lógica, se asume que la posición más baja de la perilla (nivel 2) corresponde a los valores mínimos de operación del equipo (alrededor de 16 V y 40 A), mientras que la posición más alta (nivel 8) se asocia a los valores máximos documentados (aproximadamente 19 V y 100 A).

El nivel medio (posición 5 en la perilla) se estimó como el punto intermedio lineal entre esos dos extremos. Así, aplicando una interpolación simple sobre el rango de voltaje:

$$Voltaje_{medio} = \frac{16V + 19V}{2} = 17.5 V \quad (25)$$

Y para la corriente:

$$Corriente_{media} = \frac{40A + 100A}{2} = 70A \quad (26)$$

Se redondearon estos valores hacia las cifras más representativas y realistas con base en los cambios visuales observados en la soldadura. Así, se definieron los valores de referencia indicados en la tabla 5:

Nivel de Perilla	Valor de referencia	Valor estimado	Corriente Estimada
Bajo	2	16	40
Medio	5	17.5	30
Alto	8	19	100

Tabla 5 Valores estimados de voltaje y corriente según niveles del equipo VOL-MIG110

4.2.2 Medición de velocidad y cantidad de micro alambre

Para cuantificar la velocidad de alimentación del micro alambre durante el proceso de soldadura, se realizaron mediciones empíricas cronometradas, en las que se activó la salida de alambre durante un intervalo de 5 segundos sin generar arco eléctrico. Se utilizó una regla métrica para medir la longitud total de alambre expulsado desde la boquilla, asegurando que las condiciones de prueba fueran constantes: sin contacto con la pieza de trabajo, boquilla limpia y motor de alimentación libre de obstrucciones. Se realizaron pruebas para niveles progresivos de la perilla del equipo, desde el nivel 2 al nivel 8. Cada nivel fue medido directamente, registrando la longitud expulsada en 5 segundos. A partir de esta longitud se calculó la velocidad lineal del alambre.

Los resultados de estas mediciones se presentan en la tabla 6:

Nivel de perilla	Longitud alimentada en 5 s (cm)	Velocidad lineal (cm/s)	% del rollo de 1 kg consumido
1	18.2	3.64	0.0072 %
2	25.5	5.10	0.0101 %
3	30.5	6.10	0.0121 %
4	35.1	7.02	0.0139 %
5	39.8	7.96	0.0157 %
6	44.7	8.94	0.0177 %
7	49.2	9.84	0.0195 %

8	54.0	10.80	0.0213 %
---	------	-------	----------

Tabla 6 Velocidad de alimentación y porcentaje de uso del rollo de micro alambre.

La columna correspondiente al porcentaje del rollo consumido se calculó tomando como referencia una longitud total aproximada de 253 metros por cada rollo de 1 kg de micro alambre de 0.8 mm de diámetro. En la práctica, al contar con los valores medidos para cada nivel de perilla, este porcentaje puede utilizarse para realizar aproximaciones de uso total o estimar cuántas muestras pueden realizarse antes de requerir el cambio de carrete.

Esta medición es útil para analizar indirectamente el aporte de material y su posible relación con la forma y calidad del cordón de soldadura generado, especialmente al evaluar diferencias entre las caligrafías establecidas. Los valores aquí presentados fueron utilizados posteriormente para asociar cada imagen registrada con su correspondiente condición de alimentación, formando parte del conjunto de datos base para el entrenamiento y evaluación del modelo de clasificación.

4.3 Matriz de prueba por caligrafía

Dada la estructura experimental definida previamente, en esta sección se documenta el llenado de las matrices de prueba para cada caligrafía. Estas matrices registran las combinaciones de parámetros utilizadas durante la fabricación de cordones de soldadura, permitiendo visualizar la distribución y cobertura de las pruebas realizadas. La matriz se estructura como una cuadrícula donde cada celda representa una combinación única de estos tres parámetros, asociada a una prueba específica: el nivel de voltaje (estimado en 16, 17 y 19 V para niveles bajo, medio y alto), la velocidad de alimentación del micro alambre (5.1, 7.95 y 10.8 cm/s para niveles 2, 5 y 8, respectivamente) y la velocidad de desplazamiento del robot, fijada en dos valores: 5 mm/s y 10 mm/s, mostrando 18 combinaciones posibles.

Cada combinación de parámetros genera una celda dentro de la matriz, identificada mediante un código alfanumérico estructurado como XX_V_M_R, donde XX representa la caligrafía, V el nivel de voltaje, M la velocidad del micro alambre, y R la velocidad del robot.

La selección de combinaciones se realizó partiendo de una velocidad fija del robot (por columna), y recorriendo en cada bloque todas las combinaciones posibles entre niveles de voltaje y alimentación de micro alambre. Una vez completado un bloque para una velocidad, se incrementaba la velocidad del robot y se repetía el ciclo. Este procedimiento se

aplicó por separado para cada caligrafía, debe de ser adaptando acorde a los parámetros geométricos (como paso, largo y ancho del cordón) al patrón deseado.

Para facilitar la interpretación visual, cada celda en las matrices fue coloreada siguiendo un sistema de semáforo: verde para una combinación ejecutada y válida, amarillo: combinación ejecutada, pero con condiciones dudosas o marginales y rojo: combinación descartada. Las Figuras 35 a 38 muestran las matrices de pruebas generadas para cada caligrafía

4.3.1 Matriz de prueba de caligrafía zigzag

La caligrafía en zigzag mostró una buena tolerancia a variaciones en la velocidad del micro alambre, pero fue sensible a combinaciones con voltaje bajo y velocidad alta del robot, donde el material no fundía adecuadamente. En estos casos, el cordón presentaba discontinuidades. Las celdas rojas reflejan combinaciones que generaron defectos importantes o inestabilidad en el arco.

Código Prueba		ZZ_2_2_10 ZZ_b_b_a	ZZ_2_2_10 ZZ_b_b_a	ZZ_5_2_10 ZZ_m_b_a	ZZ_5_2_10 ZZ_m_b_a	ZZ_8_2_10 ZZ_a_b_a	ZZ_8_2_10 ZZ_a_b_a	ZZ_2_5_10 ZZ_b_m_a	ZZ_2_5_10 ZZ_b_m_a	ZZ_5_5_10 ZZ_m_m_a	ZZ_5_5_10 ZZ_m_m_a	ZZ_8_5_10 ZZ_a_m_a	ZZ_8_5_10 ZZ_a_m_a	ZZ_2_8_10 ZZ_b_a_a	ZZ_2_8_10 ZZ_b_a_a	ZZ_5_8_10 ZZ_m_a_a	ZZ_5_8_10 ZZ_m_a_a	ZZ_8_8_10 ZZ_a_a_a	ZZ_8_8_10 ZZ_a_a_a
Voltaje (V)	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19	
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	7.95	7.95	7.95	10.8	10.8	10.8	10.8	10.8	10.8	10.8	10.8	10.8	
Vel. Soldadura (mm/seg)	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	

Figura 35 Matriz de pruebas para caligrafía zigzag

4.3.2 Matriz de prueba de caligrafía medialuna

Este patrón mostró alta sensibilidad a velocidades altas del robot, y velocidad de micro alambre lento, donde el cordón tendía a romperse o presentaba pérdida de simetría.

Las zonas verdes de la matriz reflejan las combinaciones que mantuvieron continuidad en la trayectoria y consistencia en el aporte de material.

Código Prueba	ML_2_2_10 ML_b_b_a	ML_5_2_10 ML_m_b_a	ML_8_2_10 ML_a_b_a	ML_2_5_10 ML_b_m_a	ML_5_5_10 ML_m_m_a	ML_8_5_10 ML_a_m_a	ML_2_8_10 ML_b_a_a	ML_5_8_10 ML_m_a_a	ML_8_8_10 ML_a_a_a
Voltaje (V)	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	10.8	10.8	10.8
Vel. Soldadura (mm/seg)	5	5	5	5	5	5	5	5	5
Código Prueba	ML_2_2_10 ML_b_b_a	ML_5_2_10 ML_m_b_a	ML_8_2_10 ML_a_b_a	ML_2_5_10 ML_b_m_a	ML_5_5_10 ML_m_m_a	ML_8_5_10 ML_a_m_a	ML_2_8_10 ML_b_a_a	ML_5_8_10 ML_m_a_a	ML_8_8_10 ML_a_a_a
Voltaje (V)	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	10.8	10.8	10.8
Vel. Soldadura (mm/seg)	10	10	10	10	10	10	10	10	10

Figura 36 Matriz de pruebas para caligrafía medialuna.

4.3.3 Matriz de prueba de caligrafía cuadrada

La caligrafía cuadrada se comportó de manera robusta en condiciones medias y altas de voltaje. Sin embargo, en configuraciones con baja velocidad del micro alambre y robot rápido, se observó falta de penetración y cordones con poca cohesión entre líneas. La

geometría ortogonal del patrón facilitó la ejecución del robot, pero evidenció el impacto directo de los parámetros en la apariencia del cordón.

Código Prueba	Cu_2_2_5	Cu_b_b_b	Cu_5_2_5	Cu_m_b_b	Cu_8_2_5	Cu_a_b_b	Cu_2_5_5	Cu_b_m_b	Cu_5_5_5	Cu_m_m_b	Cu_8_5_5	Cu_a_m_b	Cu_2_8_5	Cu_b_a_b	Cu_5_8_5	Cu_m_a_b	Cu_8_8_5	Cu_a_a_b
Voltaje (V)	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	5.1	7.95	7.95	10.8	10.8	10.8	5.1	10.8	10.8	5.1	10.8	10.8
Vel. Soldadura (mm/seg)	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
Código Prueba																		
Voltaje (V)	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	5.1	7.95	7.95	10.8	10.8	10.8	5.1	10.8	10.8	5.1	10.8	10.8
Vel. Soldadura (mm/seg)	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10

Figura 37 Matriz de pruebas para caligrafía cuadrada

4.3.4 Matriz de prueba de caligrafía circular

Esta caligrafía presentó los mayores desafíos en términos de ejecución, dado que requiere mayor control sobre la trayectoria. A pesar de su buena respuesta en configuraciones de alta energía (voltaje y micro alambre altos), se identificaron zonas críticas en la matriz al combinar voltaje bajo con velocidades de robot rápidas, donde el cordón se tornaba irregular o incompleto.

Código Prueba	Ci_2_2_5								
	Ci_b_b_b	Ci_b_b_b	Ci_m_b_b	Ci_m_b_b	Ci_a_b_b	Ci_a_b_b	Ci_b_m_b	Ci_b_m_b	Ci_a_m_b
Voltaje (V)	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	10.8	10.8	10.8
Vel. Soldadura (mm/seg)	5	5	5	5	5	5	5	5	5
Código Prueba	Ci_2_2_10								
	Ci_b_b_a	Ci_m_b_a	Ci_a_b_a	Ci_a_b_a	Ci_b_m_a	Ci_m_m_a	Ci_a_m_a	Ci_b_a_a	Ci_m_a_a
Voltaje (V)	16	17	19	16	17	19	16	17	19
Vel Microalambre (cm/s)	5.1	5.1	5.1	7.95	7.95	7.95	10.8	10.8	10.8
Vel. Soldadura (mm/seg)	10	10	10	10	10	10	10	10	10

Figura 38 Matriz de pruebas para caligrafía circular

4.4 Obtención y preparación de imágenes

La obtención de imágenes como proceso de recolección de datos, representa el insumo principal para el posterior entrenamiento del modelo de clasificación basado en redes neuronales convolucionales. La toma de imágenes se realizó después de concluir cada prueba de soldadura correspondientemente etiquetada según las reglas mencionadas durante la etapa de metodología.

Se empleó la cámara integrada de un teléfono móvil modelo Honor X8, configurada en modo automático y con una distancia entre el lente y el cordón constante a 10 cm, establecida de forma experimental sin distorsión por cercanía y con una cobertura completa de la sección relevante del cordón. Siguiendo la metodología planteada, cada cordón fue fotografiado desde tres ángulos distintos: frontal y diagonales superiores para capturar

información como la forma del perfil, la simetría, la distribución de material y la textura superficial. Además, contribuyó como un aumento de datos de manera análoga.

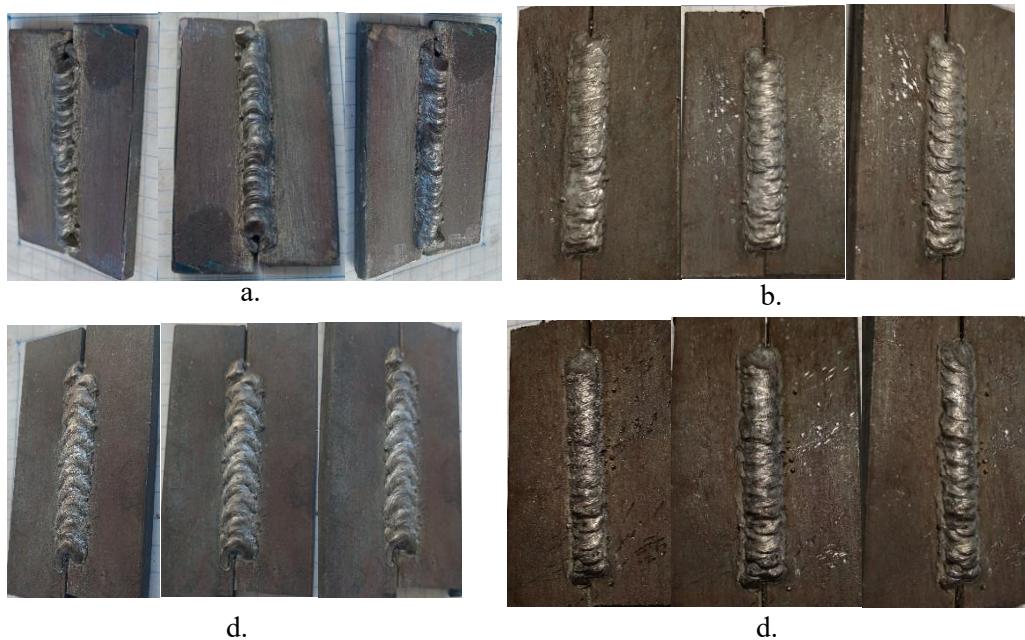


Figura 39 Toma de fotografías 3 ángulos, para 4 caligrafías (a. circular b. cuadrada c. media luna d. zigzag

Durante esta etapa, se realizó una inspección visual inmediata para asegurar la claridad de la imagen, la correcta exposición y la ausencia de elementos distractores como sombras proyectadas o reflejos metálicos. Aquellas imágenes que no cumplían con estos criterios fueron descartadas y reemplazadas mediante una nueva toma bajo los mismos parámetros. Todas las imágenes seleccionadas para análisis posterior fueron almacenadas y clasificadas cuidadosamente en carpetas organizadas por tipo de caligrafía. En la figura 39 se pueden ver ejemplos de fotografías en 3 diferentes ángulos de cada caligrafía de soldadura.

4.4.1 Procesamientos utilizados

Una vez obtenidas las imágenes de los cordones de soldadura, se procedió con su preprocesamiento, con el fin de normalizar las condiciones de entrada al modelo y asegurar la coherencia en la estructura del conjunto de datos. El procesamiento de imágenes se implementó en lenguaje Python, utilizando las bibliotecas especializadas OpenCV y NumPy. Las funciones fueron estructuradas para ser aplicadas de manera sistemática sobre todos los archivos contenidos en la base de datos. El flujo de preprocesamiento consistió en las siguientes etapas:

4.4.1.1 Redimensionamiento:

Todas las imágenes fueron redimensionadas a una resolución uniforme de 140×224 píxeles, en escala de grises, lo cual se definió como tamaño de entrada para el modelo de red neuronal. Esta resolución fue seleccionada con base en pruebas preliminares que demostraron una buena relación entre desempeño, velocidad de entrenamiento y consumo de memoria.

4.4.1.2 Conversión a escala de grises:

Las imágenes RGB fueron convertidas a escala de grises para reducir la dimensionalidad y centrarse en las características estructurales del cordón. Esta decisión también buscó simplificar el modelo y reducir el ruido visual innecesario.

4.4.1.3 Ecualización de histograma:

Se aplicó un proceso de ecualización de histograma para mejorar el contraste global de las imágenes y destacar los bordes y relieves del cordón. Esta técnica distribuye de forma más uniforme los niveles de intensidad, facilitando la extracción de patrones visuales por parte del modelo. En la figura 40 se puede ver el paso de procesamiento para 1 caligrafía.

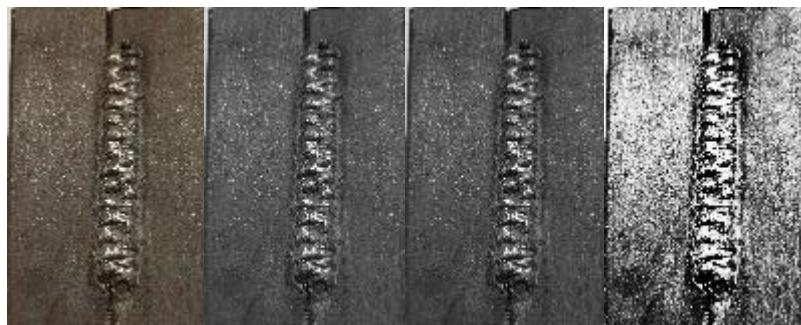


Figura 40 Procesamiento aplicado a) Redimensionamiento (100x160)

4.4.1.4 Verificación visual posprocesamiento:

Finalmente, se realizó una validación visual de las imágenes procesadas, verificando que la estructura del cordón fuera claramente visible y que no se hubieran introducido distorsiones o artefactos indeseados durante las etapas anteriores. Las imágenes que no cumplían con estos criterios fueron descartadas o reprocesadas.

El conjunto final de imágenes procesadas fue almacenado en un directorio independiente y utilizado como entrada para el entrenamiento del modelo de red neuronal. Esta secuencia de procesamiento se diseñó para ser replicable y adaptable a futuras bases de datos, permitiendo ajustes mínimos si se emplean cámaras o resoluciones diferentes. En la figura 41 se puede observar un ejemplo de redimensionamiento de imagen.

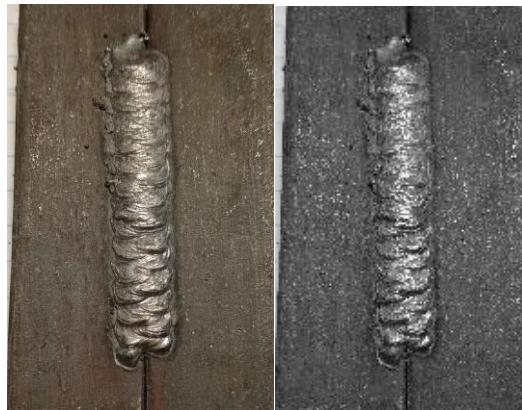


Figura 41 Imagen antes y después de redimensionamiento

4.4.2 Base de datos generada y acomodo en carpetas según código

Una vez concluido el proceso de captura y preprocesamiento de imágenes, se estructuró la base de datos para facilitar su uso dentro del flujo de entrenamiento y validación del modelo de red neuronal convolucional. La organización incluye que cada imagen estuviera correctamente etiquetada y localizada dentro de una carpeta correspondiente a su clase como se muestra en el siguiente diagrama. En este proyecto con clases principales (cuadrada, zigzag, circular y medialuna), correspondientes a los estilos de caligrafía de cordones de soldadura previamente programados en el robot. Para cada una de estas clases se generó un conjunto equilibrado de imágenes, obtenidas desde tres ángulos diferentes (frontal, lateral y diagonal). La estructura de carpetas (ver figura 42) se utilizó para ser compatible con los métodos de carga de datos utilizados en Python (por ejemplo, ImageDataGenerator de Keras o ImageDatastore en MATLAB).

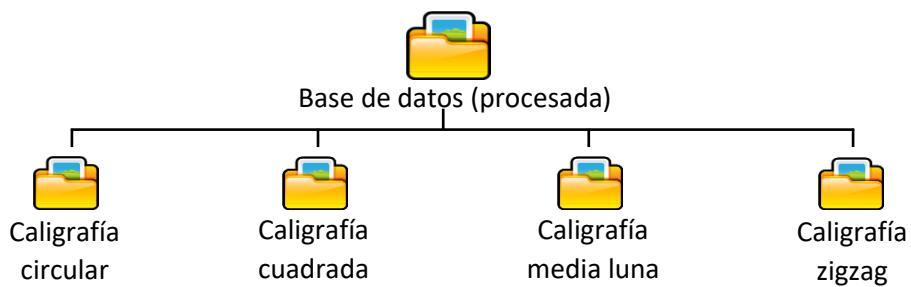


Figura 42 Estructura de carpetas de base de datos WeldingNet

Cada imagen fue identificada, acorde a la nomenclatura propuesta en esta metodología, que incluye la clase y número de muestra. Acorde a lo usual, se dividieron en subconjuntos de entrenamiento, validación y prueba, con una distribución típicamente adoptada del 60% para entrenamiento, 20% para validación y 20% para prueba, utilizando herramientas para seleccionar imágenes de forma aleatoria sin repetirse o compartirse entre estos conjuntos.

4.5 Implementación de la red neuronal convolucional (CNN)

4.5.1 Arquitectura seleccionada

La arquitectura seleccionada para este proyecto corresponde a la combinación de imágenes preprocesadas en escala de grises y con una resolución de 140×224 píxeles. La red está compuesta por cinco bloques principales de procesamiento convolucional, cada uno seguido por una capa de agrupamiento (pooling) que permite reducir progresivamente las dimensiones espaciales mientras se conservan las características relevantes del cordón. La arquitectura detallada se puede observar en la figura 43:



Figura 43 Arquitectura WeldingNet

Esta configuración fue el resultado de una serie de pruebas experimentales con distintas resoluciones de entrada (100×50 , 160×100 , 224×140 , 224×224), donde se evaluó el impacto de la escala espacial en la precisión del modelo. Se determinó que la resolución de 140×224 ofrecía el mejor equilibrio entre detalle visual, estabilidad en el entrenamiento y eficiencia computacional. Resoluciones menores provocaban pérdida de información, mientras que resoluciones mayores no ofrecían mejoras significativas y aumentaban el tiempo de entrenamiento. Además, se descartaron modelos preentrenados más complejos al no aportar beneficios sustanciales frente a una arquitectura personalizada y optimizada para este conjunto de datos.

A medida que las imágenes atraviesan estas capas, las activaciones representan características cada vez más abstractas, pasando de contornos y bordes a patrones complejos como secuencia de ondulaciones, textura repetitiva, u orientación angular.

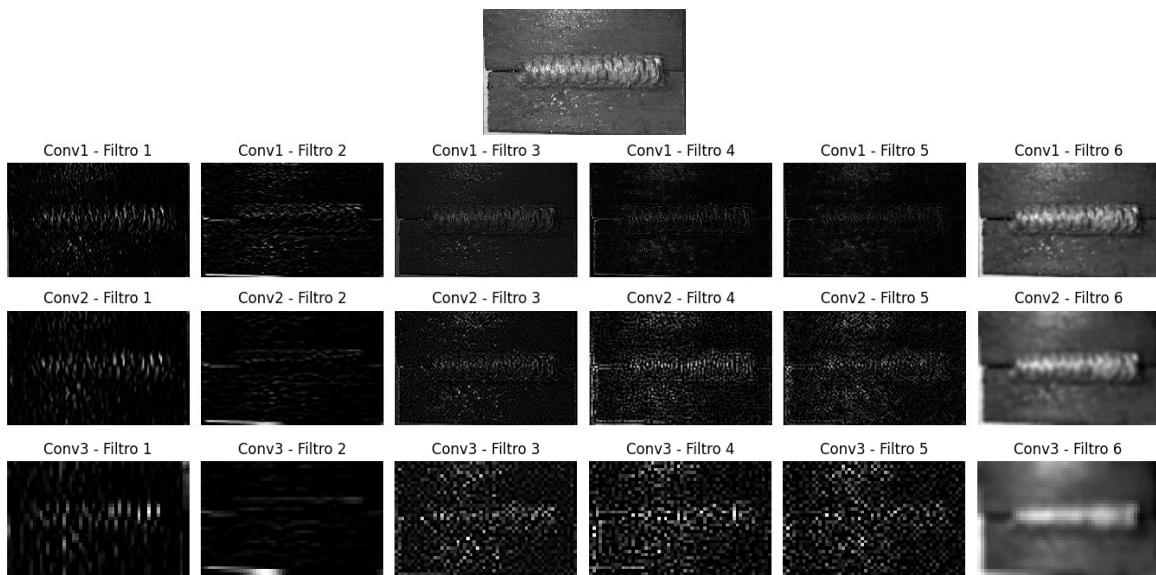


Figura 44 Ejemplo de las primeras 3 convoluciones a una imagen de caligrafía cuadrada

En la figura 44 se puede ver un ejemplo de las primeras 3 capas de convolución. Posteriormente, la salida tridimensional del último bloque de convolución es transformada en un vector unidimensional mediante la capa de aplanamiento (flattening) como se puede observar en la figura 45.

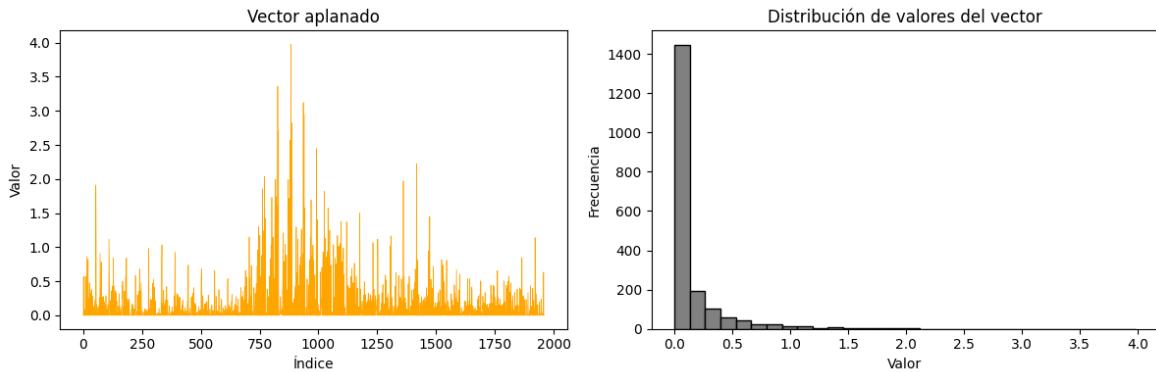


Figura 45 Grafica de vector aplanado

Finalmente, este vector pasa por una capa densa totalmente conectada como se puede observar en la figura 46:

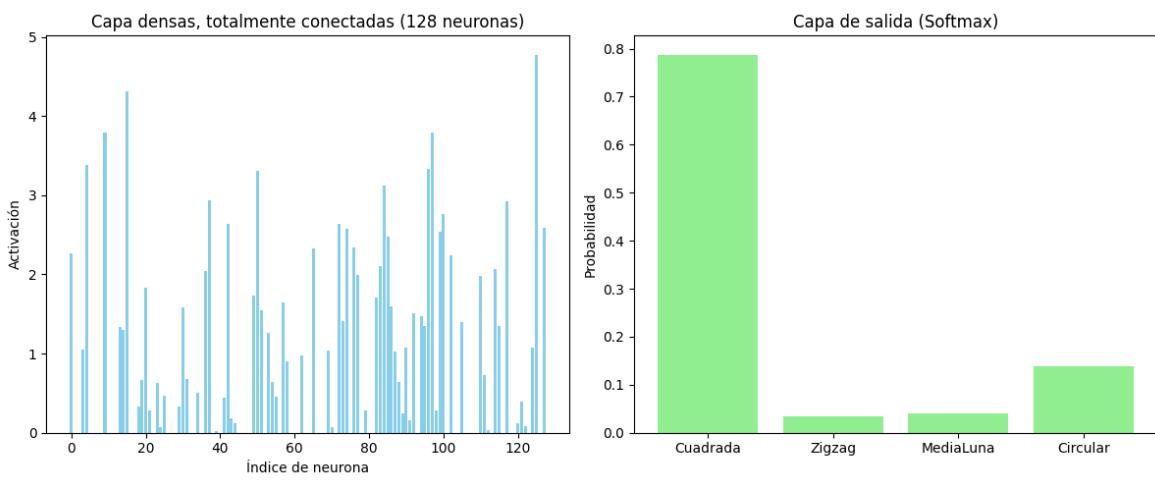


Figura 46 Grafica de capas densas totalmente conectadas y capas de salida (softmax)

4.5.2 Entrenamiento del modelo

El proceso de entrenamiento de la red neuronal convolucional descrita en la sección anterior se llevó a cabo utilizando el conjunto de imágenes preprocesadas y organizadas conforme al esquema de carpetas por clase. El modelo fue entrenado empleando el algoritmo de optimización Adam, estable en problemas de clasificación multiclase. Se utilizó una función de pérdida de entropía cruzada categórica (categorical cross-entropy), adecuada para este tipo de tareas con múltiples clases mutuamente excluyentes. La métrica principal para evaluar el desempeño durante el entrenamiento fue la precisión (accuracy), aunque posteriormente se analizaron otras métricas complementarias como la precisión por clase, recall y F1-score. Los parámetros de entrenamiento utilizados en la configuración final se pueden ver en la tabla 7:

Parámetro	Valor usado
Número de épocas	30
Tamaño de batch	32
Taza de aprendizaje	0.001
Optimizador	Adam
Regularización	En algunas pruebas se empleó dropout (0.5) en la capa totalmente conectada

Tabla 7 Parámetros de entrenamiento *WeldingNet*.

Además, se aplicaron técnicas de preparación y aumento de datos, orientadas tanto a la normalización como al balanceo del conjunto de entrenamiento. El preprocesamiento incluyó una rotación automática de imágenes en orientación vertical, que fueron corregidas a horizontal (rotación de 90° en sentido horario), así como un redimensionamiento uniforme a 140×224 píxeles, y la conversión a escala de grises.

En paralelo, se implementó una estrategia de balance de clases por duplicación, mediante la cual las clases con menos imágenes fueron completadas seleccionando aleatoriamente muestras existentes de esa clase y generando copias con nombre diferente. Cabe señalar que, en esta etapa, no se aplicaron aún transformaciones geométricas aleatorias como espejos horizontales, rotaciones en pequeños ángulos o modificaciones de intensidad, lo cual se reserva como trabajo futuro en una etapa de refinamiento del modelo.

Durante el entrenamiento del modelo se observó una evolución progresiva de las curvas de pérdida y precisión, con una tendencia de convergencia en las primeras 20 épocas. La validación mantenía una diferencia estable frente al entrenamiento, lo cual indica un buen equilibrio entre aprendizaje y generalización. Las mejores métricas de desempeño se obtuvieron alrededor de la época 25, momento a partir del cual los valores comenzaron a estabilizarse (ver figura 47).

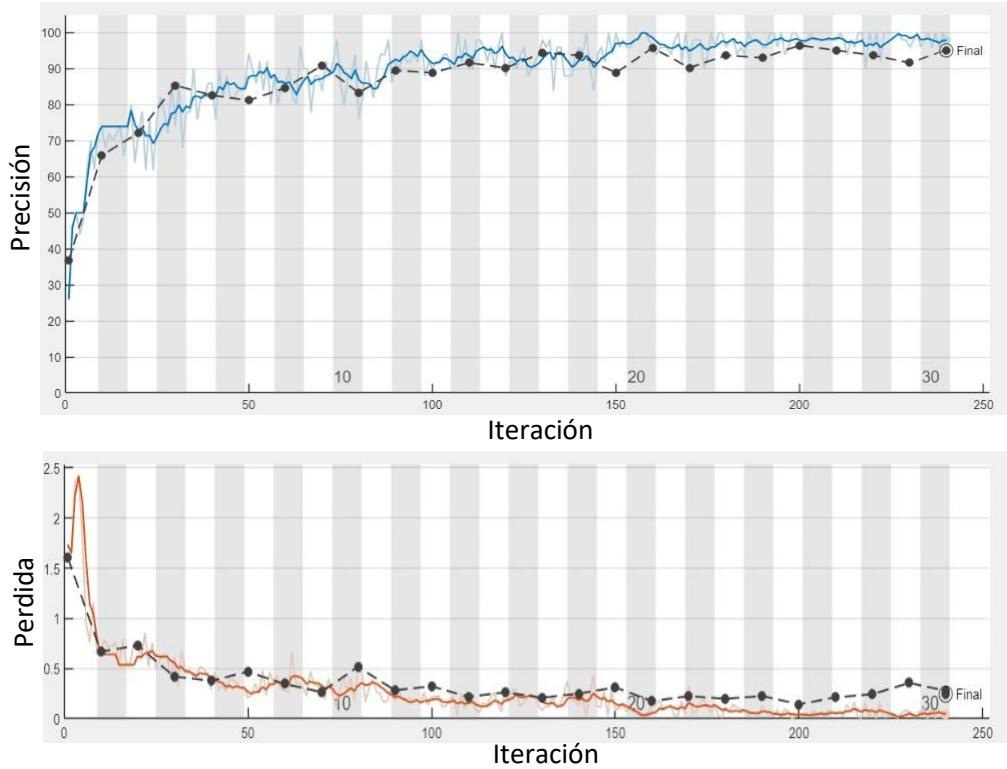


Figura 47 Graficas de entrenamiento de WeldingNet

El entrenamiento fue realizado en plataforma MATLAB, empleando un entorno con capacidad de cómputo adecuada para acelerar las operaciones matriciales del entrenamiento (CPU de alto rendimiento y, opcionalmente, GPU si disponible). El tiempo total de entrenamiento depende del tamaño de la base de datos y de la configuración de filtros y capas utilizada. Esta etapa concluyó con el almacenamiento del modelo entrenado en un archivo *.mat, utilizado posteriormente para pruebas en lote y para integrarse en la interfaz de usuario desarrollada en la etapa final del proyecto.

4.6 Validación del modelo

La validación del modelo se llevó a cabo para evaluar su capacidad para generalizar frente a nuevas muestras y prevenir el sobreajuste (Overfitting). El conjunto de datos fue dividido utilizando una proporción del 60% para entrenamiento, 20% para validación, y 20% para prueba, mediante la función `splitEachLabel` de MATLAB con selección aleatoria por clase. Esta distribución asegura que cada subconjunto mantenga una representación balanceada de las cuatro categorías de caligrafía de cordón: cuadrada, zigzag, circular y medialuna.

A lo largo de las 30 épocas de entrenamiento, se evaluó la precisión (accuracy) sobre este subconjunto al finalizar cada época, donde la precisión sobre el conjunto de validación se estabilizó por encima del 95% a partir de la época 20, manteniéndose en ese rango hasta el final del proceso. Por lo que el modelo logró aprender las características distintivas de cada clase sin depender de ejemplos específicos. Asimismo, los valores de pérdida (loss) sobre el conjunto de validación presentaron una tendencia decreciente durante las primeras 15–20 épocas, estabilizándose después sin oscilaciones significativas.

Una vez concluido el entrenamiento, se evaluó el modelo sobre el conjunto de prueba independiente. La clasificación final de cada muestra permitió calcular la matriz de confusión, presentada en la figura 48. Dicha matriz muestra la distribución de aciertos y errores para cada clase, facilitando el análisis de patrones de confusión comunes entre caligrafías.

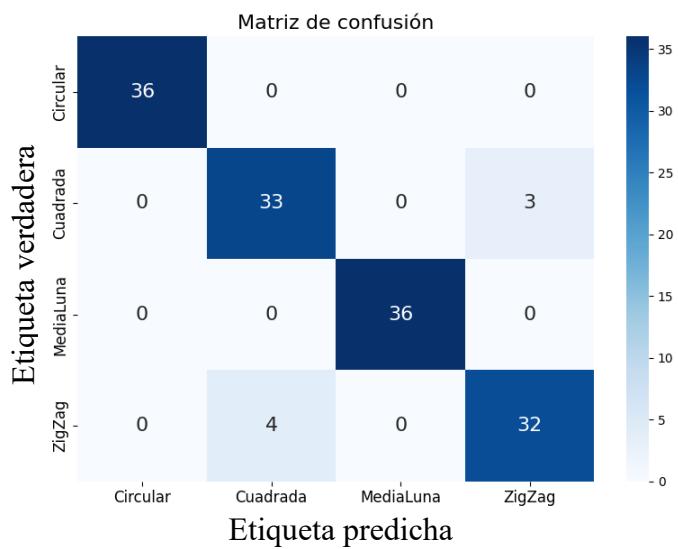


Figura 48 Matriz de confusión para caligrafías de soldadura

La diagonal dominante confirma que la mayoría de las predicciones fueron correctas, y los pocos errores se concentran principalmente entre clases con patrones visualmente similares (cuadrada y zigzag). Esto sugiere que, aunque el modelo tiene alta precisión, las clases que comparten geometrías más suaves o formas cerradas tienden a presentar confusiones marginales. El desempeño fue alto principalmente en las clases circular y medialuna, donde posiblemente las trayectorias suaves y bien definidas del cordón permitieron una extracción clara de características por parte del modelo. Por otro lado, en las

clases zigzag y cuadrada se observaron ligeras disminuciones en algunas métricas, probablemente atribuibles a la mayor variabilidad geométrica, la presencia de bordes pronunciados o la similitud estructural en ciertos fragmentos del cordón en ciertas condiciones. Además de la matriz de confusión, se calcularon métricas de desempeño para cada clase (precisión, sensibilidad y F1-score. Estos valores se resumen en la tabla 8:

Clase	Precisión	Recall	F1-Score	Soporte
Circular	1.00	1.00	1.00	36
Cuadrada	0.89	0.92	0.90	36
Media luna	1.00	1.00	1.00	36
Zigzag	0.91	0.89	0.90	36

Tabla 8 Métricas por clase.

La precisión global alcanzada durante la fase de prueba fue también del 95.14 %, coherente con los resultados del conjunto de validación. Junto con esta métrica, se calcularon el valor *F1-score*, la sensibilidad (*recall*) y la precisión (*precision*) para cada clase, como se muestra en la tabla 9. Todas las métricas reportadas se ubicaron por encima del 94 %, lo que ratifica el balance entre aciertos y errores tanto positivos como negativos.

Métrica	Valor
Exactitud (Accuracy)	0.95139
Precisión (Macro)	0.95154
Recall (Macro)	0.95139
F1-Score (Macro)	0.95138

Tabla 9 Métricas globales.

4.7 Desarrollo e implementación del software de validación

4.7.1 Descripción de la interfaz (layout)

Para facilitar la evaluación visual y la validación rápida del tipo de caligrafía de soldadura tipo MIG, se desarrolló una interfaz gráfica de usuario (GUI) en MATLAB, implementada mediante programación estructurada con uifigure y componentes uicontrol. Esta interfaz, denominada WeldingNet GUI, permite cargar imágenes individuales o carpetas completas, aplicar el modelo convolucional previamente entrenado y comparar el resultado obtenido contra una caligrafía objetivo-preseleccionada, simplificando la inspección directa por parte de personal operativo o de calidad. En la figura 49 se presenta una captura real de su implementación.

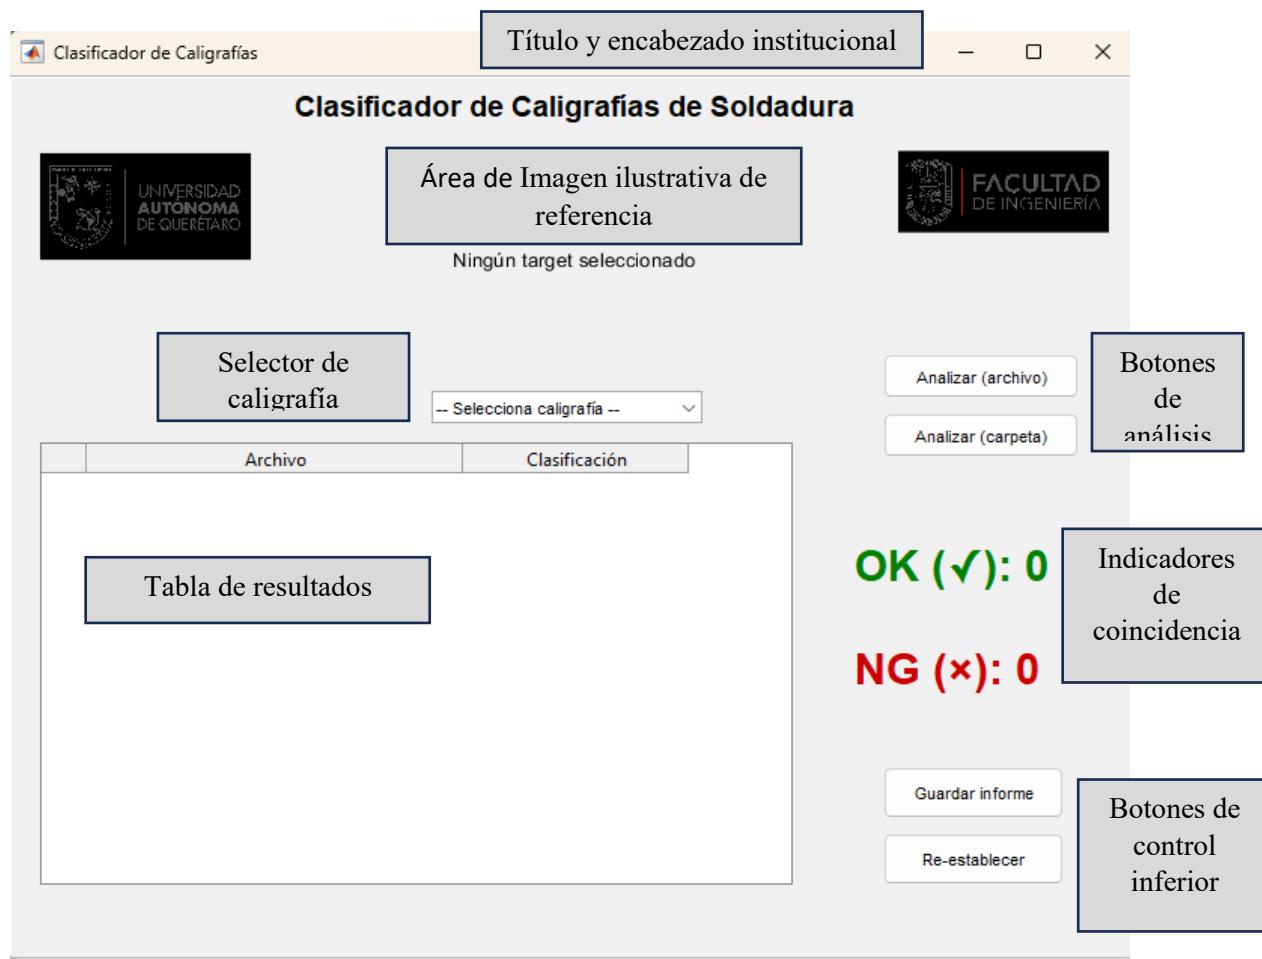


Figura 49 Matriz de confusión para caligrafías de soldadura.

El resumen de la composición de la interfaz se puede observar en la tabla 10:

Componente de Interfaz	Descripción
Título encabezado institucional y	En la parte superior se muestra el nombre de la herramienta ("Clasificador de Caligrafías de Soldadura") y los logotipos institucionales de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro.
Selector de caligrafía objetivo	Mediante un menú desplegable (popupmenu), el usuario puede seleccionar una de las cuatro clases esperadas: circular, cuadrada, medialuna o zigzag. Esta selección define la caligrafía que se desea encontrar en las imágenes evaluadas, y contra la cual se evaluará el desempeño del modelo.
Imagen ilustrativa de referencia	Tras seleccionar una caligrafía objetivo, se muestra una imagen ejemplo en la parte superior central para facilitar la comparación visual del usuario con la muestra que va a analizar.
Botones de análisis	Dos botones permiten cargar y analizar imágenes, el primer botón de Analizar (archivo) permite seleccionar y clasificar una sola imagen, mientras que el botón Analizar (carpeta) permite evaluar un conjunto de imágenes en una carpeta, procesándolas de manera automatizada.
Tabla de resultados:	Se refiere a una tabla tipo uitable muestra los archivos analizados y la clasificación que el modelo asignó a cada uno. Esta tabla permite seguimiento visual de múltiples pruebas sin cerrar la aplicación.
Indicadores de coincidencia	Se incluyen contadores numéricos para mostrar el número de archivos clasificados como OK (coinciden con la caligrafía objetivo) y NG (no coinciden). Estos contadores se actualizan automáticamente después de cada análisis y permiten una verificación inmediata del lote.
Botones de control inferior	Guardar informe: permite exportar los resultados obtenidos (tabla con nombres de archivo y clasificación) a un archivo .txt o .csv como respaldo de la evaluación. Reestablecer: reinicia la interfaz borrando los datos, imagen seleccionada y contadores, dejándola lista para una nueva evaluación.

Tabla 10 Resumen Interfaz Gráfica.

En su implementación técnica, la interfaz carga automáticamente el modelo convolucional welding.mat, que corresponde a la arquitectura seleccionada en la etapa de entrenamiento. La imagen para evaluar es preprocesada (escalada a 100×160 píxeles, convertida a escala de grises y ecualizada por histograma) antes de ser clasificada. La clasificación se realiza mediante la función "classify" de MATLAB, y el resultado es almacenado junto con el nombre del archivo en la tabla de resultados. Esta herramienta está diseñada como un apoyo visual directo al proceso de validación de soldadura, permitiendo al inspector o ingeniero de calidad determinar de forma rápida si los cordones producidos

coinciden con la caligrafía esperada. Además, puede emplearse también por el ingeniero de procesos para verificar si el patrón programado en el robot ha sido correctamente ejecutado, ofreciendo así una solución práctica, y replicable.

4.7.2 Pantallas (vistas de uso de la interfaz)

Con el propósito de documentar el funcionamiento de la herramienta de validación desarrollada, a continuación, se presentan las principales pantallas que componen la interfaz gráfica WeldingNet. En estas vistas se ilustra la interacción del usuario con el sistema.

4.7.2.1 Pantalla inicial

La figura 50 muestra la interfaz en su estado inicial. En esta etapa, ningún modelo ha sido activado, no se ha seleccionado una caligrafía objetivo, y la tabla de resultados se encuentra vacía. Esta configuración representa el punto de partida tras abrir el programa. El usuario deberá iniciar el flujo de trabajo seleccionando el tipo de caligrafía que desea validar.

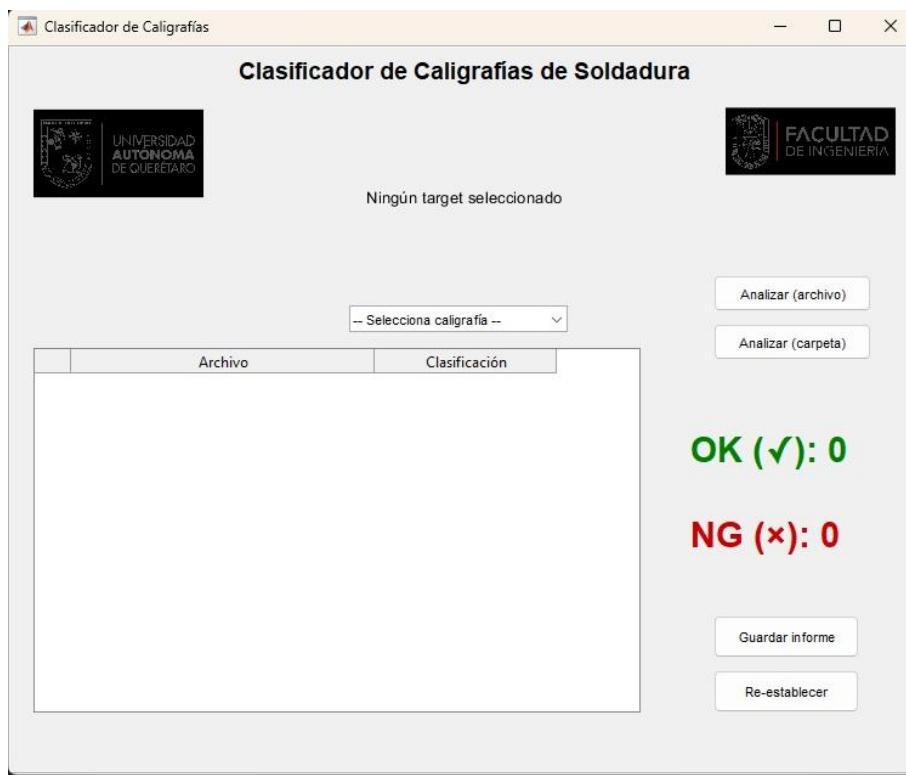


Figura 50 Pantalla inicial (WeldingNet).

4.7.2.2 Selección de caligrafía objetivo

En la figura 51 se observa el menú desplegable (pop-up menu) utilizado para seleccionar el tipo de caligrafía objetivo. Las opciones disponibles son: circular, cuadrada,

medialuna y zigzag. Esta selección determina el criterio de comparación para los archivos que serán analizados, permitiendo al sistema distinguir entre clasificaciones correctas (OK) y no coincidentes (NG).

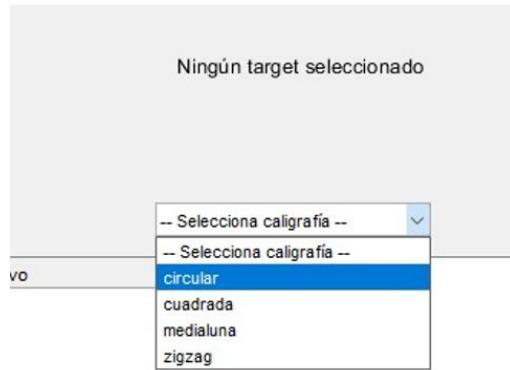


Figura 51 Menú desplegable para seleccionar la caligrafía (WeldingNet).

Una vez seleccionada la caligrafía, como se aprecia en la figura 52, el sistema despliega una imagen ilustrativa correspondiente a la clase seleccionada, lo cual proporciona una referencia visual al usuario. Además, los botones de análisis por archivo o carpeta se habilitan.



Figura 52 Selección de caligrafía objetivo (WeldingNet).

4.7.2.3 Análisis de archivo individual

El sistema permite cargar una sola imagen mediante el botón "Analizar (archivo)". Al presionar esta opción, se despliega un cuadro de diálogo para que el usuario seleccione la imagen deseada desde su explorador de archivos (figura 53).

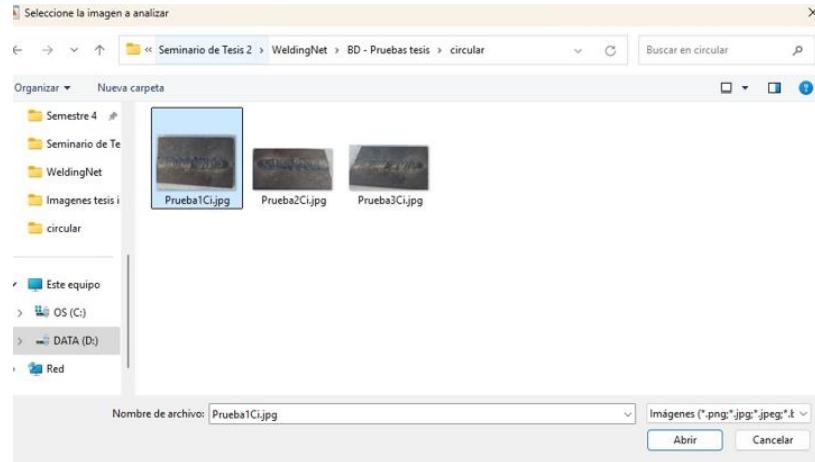


Figura 53 Selección de archivo individual (WeldingNet).

Tras seleccionar la imagen, esta es procesada y clasificada automáticamente. En la figura 54 se muestra el resultado: la imagen *Prueba1Ci.jpg* fue clasificada como “Circular” y añadida a la tabla. Dado que coincide con la caligrafía objetivo-seleccionada, el sistema incrementa el contador OK.



Figura 54 Análisis individual (WeldingNet).

4.7.2.4 Análisis de carpeta

Para casos en que se desea validar múltiples archivos simultáneamente, se utiliza el botón "Analizar (carpeta)", que despliega un cuadro de diálogo para seleccionar la carpeta deseada (figura 55). Esta funcionalidad automatiza el proceso de validación sobre conjuntos de datos.

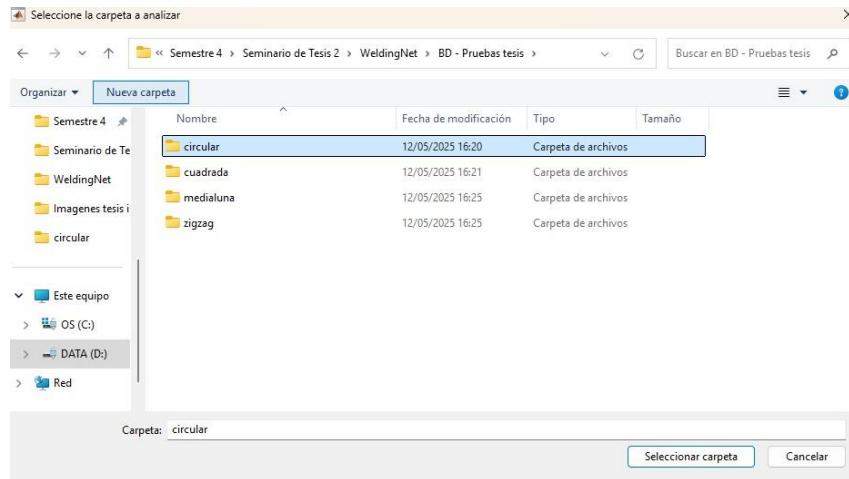


Figura 55 Selección de carpeta (WeldingNet).

Una vez seleccionada, el sistema analiza cada imagen y actualiza la tabla con sus respectivas clasificaciones. En la figura 56, todas las imágenes de la carpeta “circular” fueron correctamente clasificadas como tales, resultando en tres aciertos y un conteo final de OK = 3, NG = 0.



Figura 56 Análisis de carpeta, coincidente (WeldingNet).

4.7.2.5 Clasificación incorrecta respecto al objetivo

En la figura 57 se ejemplifica un caso donde las imágenes analizadas no coinciden con la caligrafía objetivo-seleccionada. El usuario eligió objetivo la caligrafía “circular”, pero al analizar imágenes de la carpeta correspondiente a caligrafías cuadradas, el modelo clasificó todas las entradas como “Cuadrada”. Esto genera una discrepancia con el objetivo y, por lo tanto, las tres imágenes se cuentan como no coincidentes (NG = 3, OK = 0).

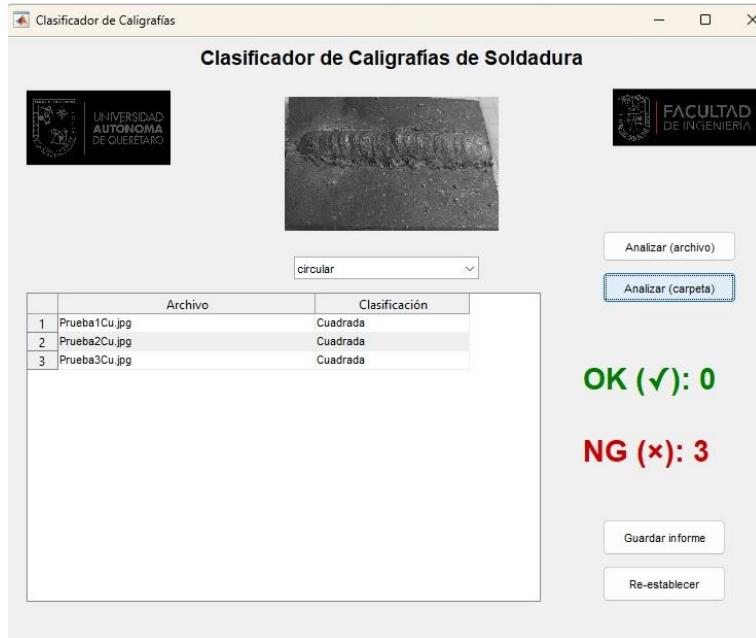


Figura 57 Análisis de carpeta, no coincidente (WeldingNet).

4.7.2.5 Guardado del informe

Una vez realizada la validación de uno o varios archivos, el sistema permite exportar los resultados mediante el botón “Guardar informe”. Esta funcionalidad genera un archivo .txt o .csv con los nombres de los archivos evaluados y sus respectivas clasificaciones. La figura 58 muestra la ventana de diálogo en la que el usuario define el nombre y la ubicación del archivo. Este informe puede servir como respaldo documental de la validación realizada, útil tanto para auditorías internas como para trazabilidad en procesos productivos.

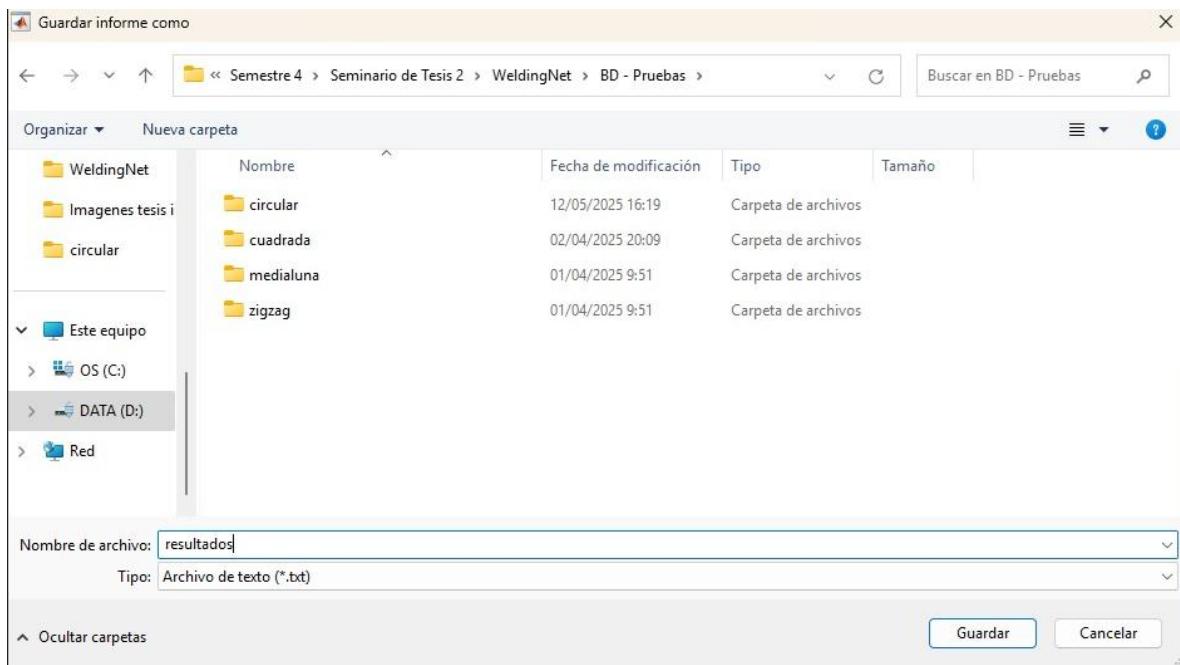


Figura 58 Guardado de reporte (WeldingNet).

Esta interfaz fue diseñada con el propósito de ser funcional, intuitiva y adaptable a entornos de inspección y verificación visual donde se requiere evaluar grandes volúmenes de imágenes en tiempo reducido, eliminando la subjetividad del juicio humano en la clasificación de cordones de soldadura.

Capítulo 5

Conclusiones y Prospectivas

5.1 Conclusiones

Las conclusiones obtenidas durante el desarrollo de este trabajo permiten probar que los objetivos planteados fueron alcanzados satisfactoriamente, desde el diseño experimental hasta la aplicación práctica del modelo de inteligencia artificial propuesto. A continuación, se describen conclusiones obtenidas durante este trabajo:

- Se diseñó y ejecutó una matriz de pruebas robóticas, que permitió reproducir 4 tipos distintos de caligrafía de soldadura tipo MIG: circular, cuadrada, medialuna y zigzag. Las trayectorias fueron definidas mediante pseudocódigos específicos que estructuraban el avance del robot en función de variables geométricas como ancho, paso y número de repeticiones, controladas desde coordenadas programadas en RAPID para celdas ABB. La matriz fue organizada en un mapa de colores que relaciona cada caligrafía con sus condiciones de generación, permitiendo una lectura visual rápida del patrón producido. Además, se utilizó una nomenclatura estandarizada para el etiquetado de las placas soldadas, facilitando la trazabilidad y posterior agrupación de las imágenes durante la etapa de entrenamiento. Este paso sentó las bases metodológicas para la recolección estructurada de datos, bajo condiciones repetibles y controladas.
- Se construyó una base de datos estructurada y balanceada, conformada por un total de 177 imágenes por caligrafía, capturadas desde tres ángulos diferentes (0° , 45° y 90°) para cada cordón. Esta estrategia de captura permitió introducir variabilidad visual que simula diferentes posiciones de inspección. Las imágenes fueron almacenadas en carpetas específicas por clase y sometidas a un proceso de preprocesamiento que incluyó conversión a escala de grises, ecualización de histograma y redimensionamiento a 140×224 píxeles.
- Se diseñó e implementó la red neuronal convolucional WeldingNet, adaptada a la clasificación de 4 caligrafías de soldadura. Esta red incluyó cinco capas convolucionales, funciones de activación ReLU, capas de max pooling intercaladas, y una capa densa final con activación softmax, orientada a la clasificación de cuatro clases. La arquitectura fue entrenada durante 30 épocas utilizando imágenes preprocesadas y alcanzó un desempeño del 95.14 % de precisión sobre el conjunto de validación. Las curvas de aprendizaje mostraron una estabilización temprana sin

signos de sobreajuste, mientras que las matrices de confusión y las métricas por clase (precisión, recall y F1-score) confirmaron una clasificación balanceada, incluso entre clases visualmente similares como zigzag y cuadrada. El modelo demostró una capacidad adecuada para generalizar patrones a partir de imágenes nuevas, cumpliendo con los estándares de desempeño esperados en tareas de visión industrial.

- Se desarrolló una interfaz gráfica de usuario, diseñada en MATLAB, para integrar de manera funcional el modelo WeldingNet con una plataforma operativa de validación visual. La interfaz permite seleccionar una caligrafía objetivo, cargar imágenes individuales o en lote, clasificar automáticamente cada cordón, visualizar el resultado y exportar informes en formato .txt o .csv. Incluye indicadores visuales de aciertos (OK) y errores (NG), así como una imagen ilustrativa del patrón esperado, facilitando el trabajo comparativo. Esta herramienta fue diseñada con enfoque industrial, siendo útil para ingenieros de calidad, ingenieros de procesos o técnicos de inspección en planta, así como para su uso en laboratorios académicos o talleres formativos, donde se requiera verificación rápida, objetiva y sin intervención manual del operador.

Además de cumplir con los objetivos establecidos, este trabajo evidenció que es posible clasificar caligrafías de cordón de soldadura sin requerir información sobre los parámetros eléctricos o mecánicos del proceso. El sistema opera únicamente con evidencia visual del cordón, esta independencia de variables externas lo hace viable para ser implementado incluso en celdas de soldadura que no cuenten con sensores avanzados, ofreciendo una solución de bajo costo para tareas de validación. Finalmente, puede concluirse que el objetivo general del proyecto fue cumplido satisfactoriamente. La metodología desarrollada fue validada técnica y funcionalmente, integrando con éxito sus etapas: desde la generación controlada de datos, el entrenamiento del modelo, hasta su implementación final a través de una interfaz práctica y operativa. Se puede decir en general que el sistema resultante es replicable y adaptable.

5.2 Prospectivas

Como resultado del trabajo desarrollado, se identifican nuevas líneas de investigación y desarrollo que podrían dar continuidad a este proyecto y acrecentar su aplicabilidad en

contextos más amplios o especializados dentro del ámbito industrial. A pesar de que el sistema propuesto ha demostrado ser funcional para la clasificación de caligrafías de cordones de soldadura MIG, existen múltiples oportunidades para ampliar su alcance técnico y operativo.

Una de las principales extensiones potenciales consiste en adaptar la metodología desarrollada para permitir la detección de variables del proceso de soldadura como el voltaje, la corriente o la velocidad de alimentación del micro alambre. Actualmente, el sistema se basa únicamente en la forma geométrica del cordón, pero con una base de datos adecuadamente etiquetada sería posible estimar estos parámetros a partir de la forma del cordón capturado en la imagen. Además de esta posibilidad, el mismo enfoque de clasificación visual puede extenderse hacia la detección de defectos comunes en la soldadura, como porosidad, mordeduras o falta de fusión. Aprovechando la infraestructura y la arquitectura de red ya probada, podría entrenarse un nuevo modelo o una variante multitarea capaz de identificar anomalías visuales que comprometan la calidad estructural del cordón. Este tipo de sistema resultaría particularmente útil en procesos donde se requiere una inspección visual automatizada más allá del patrón geométrico, contribuyendo al aseguramiento de calidad sin intervención humana.

Otra línea de trabajo viable es la migración de la solución actual hacia sistemas embebidos, que permita ejecutar el modelo en plataformas de bajo consumo energético y tamaño reducido, como NVIDIA Jetson Nano o Raspberry Pi. Esto habilitaría la instalación del sistema directamente en celdas de soldadura sin requerir computadoras industriales, facilitando su adopción en entornos de manufactura con restricciones de espacio o recursos. El despliegue en hardware embebido permitiría el monitoreo autónomo y continuo en tiempo real, ampliando la utilidad del sistema más allá del laboratorio y acercándolo a una aplicación directa en campo.

Además, esta información podría ser utilizada como parte de un sistema de retroalimentación, donde los datos visuales obtenidos tras el proceso se analicen automáticamente y generen alertas o ajustes sugeridos en los parámetros de soldadura. La

integración de este tipo de capacidades representaría un avance hacia la autonomía de celdas robóticas básicas, sin necesidad de sensores externos, utilizando únicamente visión artificial como entrada para la toma de decisiones. Este enfoque permitiría alargar la vida útil de robots industriales existentes, dotándolos de capacidades de monitoreo y corrección inteligente sin requerir cambios significativos en el hardware.

Esta línea de desarrollo no solo ampliaría la funcionalidad del sistema actual, sino que también lo convertiría en un componente valioso dentro de esquemas de manufactura inteligente para mantener estándares de calidad elevados y reducir el retrabajo o desperdicio de material. En resumen, la metodología presentada en este trabajo no se limita únicamente a la clasificación visual de patrones geométricos, sino que establece una base sólida sobre la cual se pueden construir sistemas más complejos e integrados. La extensión hacia la predicción de variables de proceso y su eventual incorporación como parte de una lógica de retroalimentación representan pasos lógicos y técnicamente viables, cuya implementación futura podría aportar beneficios significativos en términos de automatización, control de calidad y eficiencia productiva en procesos de soldadura asistida por robot.

Bibliografía

- Abadi, M., Agarwal, A., Barham, P., et al. (2016). TensorFlow: Large-scale machine learning on heterogeneous systems. *TensorFlow*. Recuperado de <https://www.tensorflow.org/>
- ABB Robotics. (2023). *RobotStudio: Offline programming and simulation software*. Recuperado de <https://new.abb.com/products/robotics/robotstudio>
- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
- Aldeoes, Y. N., Ghockle, P., & Sondkar, S. Y. (2021). Comparison of Machine Learning Algorithms for Bearing Failures Classification and Prediction. In International Conference on Advances in Electrical and Computer Technologies (pp. 269-282). Singapore: Springer Nature Singapore.
- Alejo Ramírez, Alfonso (2024), protocolo de investigación de la maestría en ciencias – mecatrónica, Clasificación de errores en rebabas de soldadura por punto de una celda de manufactura robotizada aplicando inteligencia artificial.
- Anowar, F., Sadaoui, S., & Selim, B. (2021). Conceptual and empirical comparison of dimensionality reduction algorithms (pca, kpca, lda, mds, svd, lle, isomap, le, ica, t-sne). *Computer Science Review*, 40, 100378.
- Bazurto, A. J., Quispe, E. C., & Mendoza, R. C. (2016). Causes and failures classification of industrial electric motor. In 2016 IEEE ANDESCON (pp. 1-4). IEEE.
- Bhavsar, K., Vakharia, V., Chaudhari, R., Vora, J., Pimenov, D. Y., & Giasin, K. (2022). A comparative study to predict bearing degradation using discrete wavelet transform (DWT), tabular generative adversarial networks (TGAN) and machine learning models. *Machines*, 10(3), 176.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. ISBN: 9780387310732.
- Bradski, G., & Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. O'Reilly Media.
- Castellino, A. M., Donolo, P. D., Bossio, G. R., De Angelo, C. H., & García, G. (2007). Diagnóstico de fallas en los rodamientos de motores eléctricos empleando variables eléctricas. XII Reunión de Trabajo en Procesamiento de la Información y Control, 6.
- Chapman, S. (2012). *Máquinas eléctricas*. Mc Graw Hill.
- Chen, X., Xu, W., Liu, Y., & Islam, M. R. (2019). Bearing corrosion failure diagnosis of doubly fed induction generator in wind turbines based on stator current analysis. *IEEE Transactions on Industrial Electronics*, 67(5), 3419-3430.
- Esakimuthu Pandarakone, S., Mizuno, Y., & Nakamura, H. (2019). A comparative study between machine learning algorithm and artificial intelligence neural network in detecting minor bearing fault of induction motors. *Energies*, 12(11), 2105.

Farid, D. M., Rahman, M. Z., & Rahman, C. M. (2011). An ensemble approach to classifier construction based on bootstrap aggregation. *International Journal of Computer Applications*, 25(5), 30-34.

Forsyth, D. A., & Ponce, J. (2011). *Computer Vision: A Modern Approach* (2nd ed.). Pearson. ISBN: 9780136085928.

Gangsar, P., & Tiwari, R. (2020). Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review. *Mechanical systems and signal processing*, 144, 106908.

Gavrila, H., Manescu, V., Paltanea, G., Scutaru, G., & Peter, I. (2017). New trends in energy efficient electrical machines. *Procedia Engineering*, 181, 568-574.

Gonzalez, R. C., & Woods, R. E. (2008). *Digital Image Processing* (3rd ed.). Prentice Hall. ISBN: 9780131687288.

Hong, T.S., Ghobakhloo, M., & Khaksar, W. (2014). Robotic Welding Technology: An Overview. *Journal of Manufacturing Processes*, 16(4), 56-85. DOI: 10.1016/B978-0-08-096532-1.00604-X

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27-30 June 2016. <https://doi.org/10.1109/CVPR.2016.90>

Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95.

Ji Z, Yanhong Z, Baicun W, Jiyuan Z. Human–cyber–physical systems (HCPSs) in the context of new-generation intelligent manufacturing. *Engineering* 2019;4:624–36.

Kalirane, M. (2023, enero 20). Ensemble learning in Machine learning: Bagging, boosting and stacking. *Analytics Vidhya*. <https://www.analyticsvidhya.com/blog/2023/01/ensemble-learning-methods-bagging-boosting-and-stacking/>.

Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with applications*, 38(3), 1876-1886.

Kankar, P. K., Sharma, S. C., & Harsha, S. P. (2012). Vibration-based fault diagnosis of a rotor bearing system using artificial neural network and support vector machine. *International Journal of Modelling, Identification and Control*, 15(3), 185-198.

Laganière, R. (2011). *OpenCV 2 Computer Vision Application Programming Cookbook*. Packt Publishing.

Lin, S. L. (2021). Application of machine learning to a medium Gaussian support vector machine in the diagnosis of motor bearing faults. *Electronics*, 10(18), 2266.

Li, Z., & Yan, X. (2013). Study on data fusion of multi-dimensional sensors for health monitoring of rolling bearings. *Insight-Non-Destructive Testing and Condition Monitoring*, 55(3), 147-151.

MathWorks. (s.f.). Create Apps with Graphical User Interfaces. MATLAB & Simulink. Recuperado el 21 de mayo de 2025, de https://www.mathworks.com/help/matlab/creating_guis/about-the-gui-development-environment.html

Mehta, A., Goyal, D., Choudhary, A., Pabla, B. S., & Belghith, S. (2021). Machine learning-based fault diagnosis of self-aligning bearings for rotating machinery using infrared thermography. *Mathematical Problems in Engineering*, 2021, 1-15.

Navarro-Navarro, A., Biot-Monterde, V., Ruiz-Sarrió, J. E., Antonino-Daviu, J., Osornio-Rios, R. A., & Zamudio-Ramirez, I. (2023). Detection of Corrosion in Ball Bearings in Synchronous Reluctance Motors through the Computation of Statistical Indicators of Current Signals. In 2023 IEEE 14th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED) (pp. 530-534). IEEE.

Nava, D., & Pardo, P. (Eds.). (2023). La generación eléctrica se dirige hacia un aumento en el uso de fuentes fósiles. Expansión. <https://expansion.mx/empresas/2023/10/12/generacion-electrica-dirige-fuentes-fosiles>.

Pires, J. N., Loureiro, A., Ferreira, P., Fernando, B., Godinho, T., & Morgado, J. (2003). Using Object-Oriented and Distributed Software to Assist Industrial Robotic Welding Applications. *IEEE Robotics & Automation Magazine*, June 2003, 45-55.

Popović O, Prokić-Cvetković R, Burzić M, Lukić U, Beljić B. Fume and gas emission during arc welding: hazards and recommendation. *Renew Sustain Energy Rev* 2014;37:509–16.

Ramos, B.; Santos, E. Comparative study of different digitization techniques and their accuracy. *Comput.-Aided Des.* 2011, 43, 188–206.

Roshheim, M. E. (1997). In the footsteps of Leonardo – articulated anthropomorphic robot. *IEEE Robotics & Automation Magazine*, 4(2), 12-14. <https://doi.org/10.1109/100.591641>

Rout, A., Deepak, B.B.V.L., & Biswal, B.B. (2019). Advances in Weld Seam Tracking Techniques for Robotic Welding: A Review. *Robotics and Computer-Integrated Manufacturing*, 56, 12-37. DOI: 10.1016/j.rcim.2018.08.003

Safizadeh, M. S., & Latifi, S. K. (2014). Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Information fusion*, 18, 1-8.

Saha, D. K., Hoque, M. E., & Badihi, H. (2022). Development of intelligent fault diagnosis technique of rotary machine element bearing: a machine learning approach. *Sensors*, 22(3), 1073.

Samanta, B. I. S. W. A. J. I. T., Al-Balushi, K. R., & Al-Araimi, S. A. (2003). Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection. *Engineering applications of artificial intelligence*, 16(7-8), 657-665.

Sathujoda, P. (2021). A novel corrosion detection method using wavelet transformed mode shapes of a functionally graded rotor-bearing system. *Composites Part C: Open Access*, 5, 100134.

Sen, R., Choudhury, S.P., Kumar, R., & Panda, A. (2018). A Comprehensive Review on the Feasibility Study of Metal Inert Gas Welding. *Journal of Materials Processing Technology*, 255, 212-237. DOI: 10.1016/j.jmatprotec.2018.01.030.

Sharma, A., Amarnath, M., & Kankar, P. K. (2016). Feature extraction and fault severity classification in ball bearings. *Journal of Vibration and Control*, 22(1), 176-192.

Sharma, S., Abed, W., Sutton, R., & Subudhi, B. (2015). Corrosion fault diagnosis of rolling element bearing under constant and variable load and speed conditions. *IFAC-PapersOnLine*, 48(30), 49-54.

Shipman, J. W. (2013). Tkinter 8.5 reference: A GUI for Python. New Mexico Tech. Recuperado de <https://docs.python.org/3/library/tkinter.html>

SKF. (2017). Skf.com. Recuperado el 15 de abril de 2024, de <https://www.skf.com/mx/products/rolling-bearings/bearing-failure-and-how-to-prevent-it>.

Sonka, M., Hlavac, V., & Boyle, R. (2014). *Image Processing, Analysis, and Machine Vision* (4th ed.). Cengage Learning. ISBN: 9781133593607.

Szabó, L. (2019). A survey on the efficiency improves of electrical machines. In 2019 26th International Workshop on Electric Drives: Improvement in Efficiency of Electric Drives (IWED) (pp. 1-6). IEEE.

Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer. ISBN: 9781848829343.

Tao, J., Liu, Y., & Yang, D. (2016). Bearing fault diagnosis based on deep belief network and multisensor information fusion. *Shock and vibration*, 2016.

Varela-Arregoces, E., & Campbells, E. (2011). Redes Neuronales Artificiales: una revisión del estado del arte, aplicaciones y tendencias futuras. *Investigación y Desarrollo en TIC*, 2(1), 18-27.

Video de Internet sobre formación de cordones de soldadura tipo MIG consultado en 2024. <https://www.youtube.com/watch?v=vZDntClawVw>

Wang, Q., Jiao, W., Wang, P., & Zhang, Y. (2020). A tutorial on deep learning-based data analytics in manufacturing through a welding case study. *Journal of Manufacturing Processes*. DOI: 10.1016/j.jmapro.2020.04.044

□ Wang, B., Hu, S. J., Sun, L., & Freiheit, T. (2020). Intelligent welding system technologies: State-of-the-art review and perspectives. *Journal of Manufacturing Systems*, 56, 373–391. <https://doi.org/10.1016/j.jmsy.2020.06.020>

Weman, K., & Lindén, G. (Eds.). (2006). *MIG welding guide*. Woodhead Publishing.

Yadav, E., & Chawla, V. K. (2022). An explicit literature review on bearing materials and their defect detection techniques. *Materials Today: Proceedings*, 50, 1637-1643.

Yani, I., Resti, Y., & Burlian, F. (2018). Identification of bearing failure using signal vibrations. In *Journal of Physics: Conference Series* (Vol. 1007, No. 1, p. 012067). IOP Publishing.

Yoshioka, T., & Shimizu, S. (2009). Monitoring of ball bearing operation under grease lubrication using a new compound diagnostic system detecting vibration and acoustic emission. *Tribology Transactions*, 52(6), 725-730.

Zamudio-Ramírez, I., Biot-Monterde, V., Navarro-Navarro, A., Antonino-Daviu, J., Osornio-Rios, R. A., Mäki-Ontto, P., ... & Fajt, T. (2022). Detection of corrosion in ball bearings through the computation of statistical indicators of stray-flux signals. In IECON 2022—48th Annual Conference of the IEEE Industrial Electronics Society (pp. 1-6). IEEE.

Zhang, B., Xu, L. J., & Sun, H. (2020). A Fault Diagnosis Method for Single Pitting Corrosion of Rotating Machinery Bearing Based on Wavelet Analysis. In 2020 International Conference on Robots & Intelligent System (ICRIS) (pp. 55-59). IEEE.

Zhang, Y., Shi, H., Zhou, X., & Zheng, Z. (2015). Vibration analysis approach for corrosion pitting detection based on SVDD and PCA. In 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER) (pp. 1534-1538). IEEE.

Anexos

Constancia presentación ICAPPLEC

UNIVERSIDAD DE
GUANAJUATO



El Departamento de Estudios Multidisciplinarios
otorga la presente

CONSTANCIA

A

Osiris Giuseppe García Zarate, Martín Valtierra Rodríguez, Juan Primo Benítez Rangel, Juan Pablo Amézquita Sánchez, José Luis González
Córdoba

attended the International Conference on Applied Electronics and Computers (ICApplEC) in Yuriria, Guanajuato, 6th - 8th November 2024,
and presented the work titled 'Metodología para la Clasificación de Caligrafías de Cordón de Soldadura MIG analizando el rendimiento de
diferentes algoritmos de Procesamiento de Imágenes y Aprendizaje de Máquinas' (oral presentation).

Carlos Rodríguez D.

Dr. Carlos Rodríguez Doñate
Director del Departamento de Estudios Multidisciplinarios
División de Ingeniería Campus Irapuato-Salamanca
Universidad de Guanajuato

A handwritten signature in blue ink.

Dr. Igor Guryev
Chair
ICApplEC 2024



Universidad de Guanajuato
CAMPUS IRAPUATO · SALAMANCA
DEPARTAMENTO
DE ESTUDIOS
MULTIDISCIPLINARIOS

Artículo

Metodología para la Clasificación de Caligrafías de Cordón de Soldadura MIG analizando el
rendimiento de diferentes algoritmos de Procesamiento de Imágenes y Aprendizaje de Máquinas |
JÓVENES EN LA CIENCIA

<https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/view/4700>

Metodología para la Clasificación de Caligrafías de Cordón de Soldadura MIG analizando el rendimiento de diferentes algoritmos de Procesamiento de Imágenes y Aprendizaje de Máquinas

Methodology for the Classification of MIG Welding Bead Calligraphy by analyzing the
performance of different Image Processing and Machine Learning algorithms

Osiris Giuseppe García Zarate¹, Martín Valtierra Rodríguez¹, Juan Primo Benítez Rangel¹, Juan Pablo Amézquita Sánchez¹,
José Luis González Córdoba^{1*}

¹ ENAP -Research Group, CA-Sistema Dinámicos y Control, Universidad Autónoma de Querétaro (UAQ), Campus San Juan del Río, Río
Moctezuma 249, Col. San Cayetano, San Juan del Río 76807, México.

*Autor de correspondencia: jose.gonzalez.cordoba@uq.mx

Resumen

El presente trabajo propone una metodología para la clasificación de caligrafías en cordones de soldadura utilizando técnicas de procesamiento de imágenes y aprendizaje de máquina. La metodología incluye las siguientes etapas: preprocesamiento de las imágenes mediante filtros adaptativos, extracción de características geométricas y de textura asociados a las clases de soldadura en condiciones limpias y sucias, así como la implementación de tres algoritmos de inteligencia artificial (Redes Neuronales Convolucionales - CNN, K-Nearest Neighbors - KNN y Máquinas de Soporte Vectorial - SVM) ejecutados desde una computadora personal cargada con imágenes de cordones de soldadura previamente preparadas, y la evaluación del desempeño de cada algoritmo mediante diferentes métricas de precisión y matrices de confusión. Los resultados obtenidos permiten tener un panorama general de los tres enfoques para la clasificación de patrones de soldadura, bajo distintas configuraciones de preprocesamiento y resolución de las imágenes. Cada algoritmo se evaluó bajo diferentes configuraciones de preprocesamiento y resoluciones de imagen para determinar su capacidad de distinguir características y patrones geométricos en los cordones de soldadura tipo "zigzag" y "lineal", antes y después de limpieza. Los resultados obtenidos muestran que, aunque las redes neuronales convolucionales (CNN) alcanzan mayores precisiones con imágenes de alta resolución y preprocesamiento adecuado, los modelos KNN y SVM ofrecen una clasificación efectiva incluso con resoluciones intermedias y menor preprocesamiento. Esto indica que KNN y SVM son alternativas viables cuando se busca un balance entre costo computacional y precisión, permitiendo una implementación eficiente en sistemas con recursos limitados o para aplicaciones de respuesta rápida. En particular, el modelo SVM demostró una mayor estabilidad y capacidad de generalización bajo diferentes configuraciones de preprocesamiento y resolución, mientras que KNN, aunque más sensible a variaciones en la calidad de la imagen, logró un desempeño adecuado en condiciones intermedias. La metodología propuesta es capaz de clasificar los patrones de soldadura tipo "zigzag" y "lineal", antes y después de la limpieza.

Palabras clave: Clasificación de imágenes, Redes Neuronales Convolucionales (CNN), K-Nearest Neighbors (KNN),
Máquinas de Soporte Vectorial (MSV), Caligrafías de Soldadura, Aprendizaje de máquinas.

Introducción

La automatización del control de calidad en los procesos de soldadura ha ganado relevancia en los últimos años debido al creciente aumento en los requisitos de fusión para asegurar la calidad de las uniones soldadas. Según la Sociedad Americana Soldadura (AWS, American Welding Society), se estima que aproximadamente el 60% de las fallas estructurales en componentes metálicos están relacionadas con uniones de soldadura defectuosas, lo cual impacta directamente en la seguridad y durabilidad de las piezas fabricadas, así como de los usuarios o personal que interactúan con las piezas manufacturadas (American Welding Society, 2015). Asimismo, el mercado global de automatización de soldadura alcanzó un valor de 5.2 mil millones de dólares

