



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Inteligencia Artificial

Evaluación del proceso de soldadura por resistencia por medio de imágenes termográficas y no termográficas

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Inteligencia Artificial

Presenta:

Luis Alonso Domínguez Molina

Dirigido por:

Dr. Andras Takacs

SINODALES

Dr. Andras Takacs

Presidente

Firma

Dr. Edgar Rivas

Secretario

Firma

Dr. Juan Carlos Jáuregui Correa

Vocal

Firma

Dr. José Luis González Córdoba

Suplente

Firma

Dr. Jesús Carlos Pedraza Ortega

Suplente

Firma

Director FI

Director de la Facultad

Director IP

Director de Investigación y Postgrado

Centro Universitario

Querétaro, QRO

México.

Junio 2024

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 licenciante 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 licenciante.



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.

© 2024 - Luis Alonso Domínguez Molina

All rights reserved.

Agradecimientos

Gracias a CONAHCYT por el apoyo financiero proporcionado a través de una beca, así como a la Universidad Autónoma de Querétaro por el apoyo financiero del proyecto FONDEC (20205007071001).

Abstract

The evaluation of the resistance welding process (RSW) that guarantees a satisfactory performance of mechanical characteristics without altering the physical and mechanical properties, has attracted great interest in the medical, aerospace and automotive manufacturing industry. The present work proposes a method to evaluate the quality, by the instrumentation of a manual resistance spot welding that allows monitoring the input parameters of the RSW process such as current, time and pressure, and correlates them with thermographic and digital images of the melting nugget through artificial intelligence techniques for the classification of the quality of the fusion.

This project proposes six models that receive thermographic or surface images of the welding spot to classify the visual aspect of the welding spot, predict the quality performance, and determine the process parameters of the manufacturing. To confirm the performance and variation of the models, a cross-validation method was used, in order to test the models with different training and validation sets. The results indicate that models using surface images of the welding spot exhibited better performance compared to those using thermographic images.

Resumen

La evaluación del proceso de soldadura por resistencia (RSW) que garantiza un desempeño satisfactorio de características mecánicas sin alterar las propiedades físicas y mecánicas, ha captado un gran interés en la industria de manufactura de productos médicos, aeroespaciales y automotrices. El presente trabajo propone un método, donde por medio de la construcción de un banco de pruebas que permite monitorear los parámetros de entrada como corriente, tiempo y presión, la obtención de imágenes termográficas y digitales del punto de fusión, y técnicas de inteligencia artificial para la caracterización del proceso de RSW, se evalúe la calidad y desempeño de las uniones. La metodología está conformada por la integración de un banco de pruebas para generación de muestras, el procesamiento de los datos para la generación de una base de datos, el desarrollo de red neuronal convolucional y la evaluación de los resultados. Con esto se pretende diseñar un modelo de análisis para identificar defectos del proceso de soldadura por resistencia, para la clasificación de la calidad de la fusión.

Este proyecto propone seis modelos que reciben imágenes termográficas o superficiales del punto de soldadura para clasificar el aspecto visual del punto de soldadura, predecir el resultado de atributos de calidad y determinar los parámetros del proceso de fabricación. Para confirmar el desempeño y la variación de los modelos, se utilizó un método de validación cruzada, con el fin de probar los modelos con diferentes conjuntos de entrenamiento y validación. Los resultados indican que los modelos que utilizan imágenes de la superficie del punto de soldadura presentan un mejor desempeño que los que utilizan imágenes termográficas.

Índice general

Agradecimientos

Abstract

Resumen

Índice

Índice de figuras I

Índice de tablas IV

Nomenclatura 1

1. Introducción 3

1.1. Justificación 4

1.2. Descripción del problema 5

1.3. Estructura de Tesis 6

2. Antecedentes 7

2.1. Proceso de Soldadura por Resistencia (RSW) 11

2.1.1. Fuerza de los electrodos (en inglés, Electrode Force) 12

2.1.2. Corriente de soldadura (en inglés, Weld Current) 12

2.1.3. Tiempo de soldado (en inglés, Weld Time) 13

2.2. Evaluación de la calidad 13

3. Fundamentación teórica 16

3.1. Procesamiento de imágenes 16

3.2. Redes Neuronales Convolucionales (CNN) 17

3.3. Análisis de los resultados 18

3.3.1. Validación cruzada 18

3.3.2. Correlación de Pearson 18

3.3.3. Métricas datos categóricos 18

3.3.4. Métricas datos continuos 19

4. Hipótesis 21

5. Objetivos	22
5.1. Objetivo General	22
5.1.1. Objetivos específicos	22
6. Metodología	23
6.1. Integración de banco de pruebas	23
6.1.1. Registro de Fuerza de los electrodos	25
6.1.2. Registro de Corriente de soldadura	26
6.1.3. Regulación de fuerza aplicada a los electrodos	27
6.2. Generación de muestras	28
6.2.1. Parámetros de muestras	28
6.2.2. Estado de los electrodos	29
6.2.3. Captura de imágenes	29
6.2.4. Evaluación física de la calidad	30
6.3. Procesamiento de imágenes	31
6.4. Generación de base de datos	33
6.5. Desarrollo de red neuronal convolucional	34
6.5.1. Selección de modelo	34
6.5.2. Entrenamiento de modelo	37
6.5.3. Búsqueda de hiperparámetros	38
6.5.4. Análisis de resultados	39
6.6. Especificaciones computadora y librerías	39
7. Resultados y discusión	40
7.1. Integración de banco de pruebas	40
7.2. Correlación de parámetros	43
7.3. Modelos CNN	45
7.3.1. Modelo 1 - Clasificador de calidad por categorías: buena, mala y salpicadura, en base a imágenes de superficie	45
7.3.2. Modelo 2 - Clasificador de calidad por categorías: buena, mala y salpicadura, en base a imágenes termográficas	47
7.3.3. Modelo 3 - Predicción de parámetros de calidad: diámetro de fusión y fuerza de jalón, en base a imágenes de superficie	51
7.3.4. Modelo 4 - Predicción de parámetros de calidad: diámetro de fusión y fuerza de jalón, en base a imágenes termográficas	54
7.3.5. Modelo 5 - Predicción de parámetros de entrada, en base a imágenes de superficie	57
7.3.6. Modelo 6 - Predicción de parámetros de entrada, en base a imágenes termográficas	60
7.4. Discusión	72
7.5. Publicaciones	72
7.6. Trabajo futuro	72
8. Conclusión	73
Bibliografía	77

Índice de figuras

2.1. Secuencia del proceso de soldadura por puntos, adaptada de [1].	12
2.2. Curva Lobe de soldadura por resistencia, adaptada de [2].	13
2.3. Pruebas de jalón (a) y desprendimiento (b), adaptada de [3].	14
2.4. Relación de prueba de jalón y desprendimiento con diámetro de fusión, adaptada de [3].	14
6.1. Metodología general del proyecto.	23
6.2. Banco de pruebas.	24
6.3. Diagrama de flujo del programa.	25
6.4. Circuito electrónico para registro de fuerza.	25
6.5. Circuito electrónico para registro de corriente.	26
6.6. Circuito electrónico y neumático para control de fuerza.	28
6.7. Electrodo con salpicaduras de material en la punta (a), y restaurado a su forma original (b).	29
6.8. Tamaño y configuración de las muestras de soldadura.	30
6.9. Preparación de prueba de jalón.	30
6.10. Clasificación del punto de soldadura (a) bueno, (b) malo, (c) salpicadura.	31
6.11. Coordenadas de pieza 100_B, utilizando Software Geeqie.	32
6.12. Ejemplo de imagen de superficie del proceso de soldadura por puntos estandarizada a 350×350 píxeles.	32
6.13. Ejemplo de imagen termográfica del proceso de soldadura por puntos estandarizada a 300×300 píxeles.	33
6.14. Arquitectura red LeNet-5.	36
6.15. Cabecera de modelos MobileNet, ResNet50 y DenseNet201.	37
6.16. Arreglos de entrada para modelos en base a imágenes de superficie.	38
6.17. Arreglos de entrada para modelos en base a imágenes termográficas.	38
7.1. Registro fuerza de 30 muestras con activación manual a 35 PSI - 95 PSI.	42
7.2. Pareto de efecto de parámetros de entrada en diseño de experimentos.	43
7.3. Matriz de correlación Pearson.	44
7.4. Exactitud y perdida en entrenamiento y validación de red LeNet-5 de modelo 1.	45
7.5. Exactitud y perdida en entrenamiento y validación de red MobileNet de modelo 1.	46
7.6. Exactitud y perdida en entrenamiento y validación de red ResNet50 de modelo 1.	46
7.7. Exactitud y perdida en entrenamiento y validación de red DenseNet201 de modelo 1.	46

7.8. Validación cruzada modelo 1, prueba 6.	47
7.9. Exactitud y perdida en entrenamiento y validación de red LeNet-5 de modelo 2. . . .	48
7.10. Exactitud y perdida en entrenamiento y validación de red MobileNet de modelo 2. . .	48
7.11. Exactitud y perdida en entrenamiento y validación de red ResNet50 de modelo 2. . .	49
7.12. Exactitud y perdida en entrenamiento y validación de red DenseNet201 de modelo 2.	49
7.13. Validación cruzada modelo 2, prueba 3.	50
7.14. MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 3.	51
7.15. MAE y perdida en entrenamiento y validación de red MobileNet de modelo 3.	52
7.16. MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 3.	52
7.17. MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 3. . . .	52
7.18. Validación cruzada modelo 3, prueba 2.	53
7.19. MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 4.	54
7.20. MAE y perdida en entrenamiento y validación de red MobileNet de modelo 4.	55
7.21. MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 4.	55
7.22. MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 4. . . .	55
7.23. Validación cruzada modelo 4, prueba 4.	56
7.24. MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 5.	57
7.25. MAE y perdida en entrenamiento y validación de red MobileNet de modelo 5.	58
7.26. MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 5.	58
7.27. MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 5. . . .	58
7.28. Validación cruzada modelo 5, prueba 3.	59
7.29. MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 6.	60
7.30. MAE y perdida en entrenamiento y validación de red MobileNet de modelo 6.	61
7.31. MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 6.	61
7.32. MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 6. . . .	61
7.33. Validación cruzada modelo 6, prueba 10.	62
7.34. Pieza 480, imágenes de superficie y termográfica.	65
7.35. Pieza 189, imágenes de superficie y termográfica.	65
7.36. Pieza 474, imágenes de superficie y termográfica.	65
7.37. Pieza 371, imágenes de superficie y termográfica.	66
7.38. Pieza 385, imágenes de superficie y termográfica.	66
7.39. Pieza 42, imágenes de superficie y termográfica.	66
7.40. Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría buena.	67
7.41. Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría mala.	67
7.42. Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría salpicadura.	67
7.43. Comparación de predicción vs valor real de fuerza de jalón modelos 3 y 4.	68
7.44. Comparación de predicción vs valor real de diámetro de fusión modelos 3 y 4.	68
7.45. Comparación de predicción vs valor real de ángulo entre electrodos modelos 5 y 6. . .	69
7.46. Comparación de predicción vs valor real de presión en el cilindro neumático modelos 5 y 6.	69
7.47. Comparación de predicción vs valor real de espesor modelos 5 y 6.	69
7.48. Comparación de predicción vs valor real de tiempo de soldadura modelos 5 y 6. . . .	70

7.49. Comparación de predicción vs valor real de fuerza mínima registrada en los electrodos modelos 5 y 6.	70
7.50. Comparación de predicción vs valor real de fuerza máxima registrada en los electrodos modelos 5 y 6.	70
7.51. Comparación de predicción vs valor real de corriente máxima obtenida en el proceso modelos 5 y 6.	71

Índice de tablas

2.1. Resumen de antecedentes	10
6.1. Especificaciones de celda de carga PSD-S1	26
6.2. Especificaciones de transformador de corriente TS-816	27
6.3. Especificaciones de cilindro neumático	27
6.4. Especificaciones electroválvula	27
6.5. Diseño de experimentos, 3 factores a 2 niveles y 4 repeticiones	28
6.6. Especificaciones de electrodos	29
6.7. Descripción de los atributos del base de datos	33
6.8. Rango de valores	34
6.9. Balance de clases	34
6.10. Hiperparámetros de entrenamiento	37
6.11. Espacio de búsqueda Keras Tuner	39
7.1. Resultados de fuerza real contra mediciones	40
7.2. Resultados de corriente real contra mediciones	41
7.3. Resultados arquitecturas modelo 1	45
7.4. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 1	47
7.5. Resultados arquitecturas modelo 2	48
7.6. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 2	50
7.7. Resultados arquitecturas modelo 3	51
7.8. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 3	53
7.9. Resultados arquitecturas modelo 4	54
7.10. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 4	56
7.11. Resultados arquitecturas modelo 5	57
7.12. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 5	59
7.13. Resultados arquitecturas modelo 6	60
7.14. Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 6	62
7.15. Comparación de validación cruzada modelos 1 y 2	63
7.16. Comparación de validación cruzada modelos 3 y 4	63
7.17. Comparación de validación cruzada modelos 5 y 6	64

Nomenclatura

Abreviaciones

AACD Detección de círculos asistida por ángulo

AC Corriente alterna

ADC Convertidor análogo-digital

AWS Asociación americana de soldadura

CART Árbol de clasificación y regresión

CC Coeficiente de correlación

CNN Redes neuronales convolucionales

CSV Valores separados por comas

EEPROM Memoria de solo lectura programable y borrable eléctricamente

FN Falso negativo

FP Falso positivo

ID Identificador

IF Fallo interfacial

ISO Organización internacional de normalización

MAE Error medio absoluto

MSE Error medio cuadrático

PCA Análisis de componentes principales

PF Fallo por desprendimiento

Q&P Quemado y partición

R^2 Coeficiente de determinación

RAE Error relativo absoluto
RCD Detección aleatoria de círculos
RHT Transformación aleatoria de Hough
RMS Raíz cuadrada media
RMSE Raíz del error medio cuadrático
RSE Error relativo cuadrático
RSW Soldadura por puntos de resistencia
SPS Muestras por segundo
SSD Detector de un solo disparo
TN Verdadero negativo
TP Verdadero positivo
TRIP Plasticidad inducida por la transformación
YOLO Sólo se mira una vez

Unidades

A Ampere
g Gramos
Hz Hertz
in Pulgadas
M Metro
mm Milimetro
N Newton
PSI Libras por pulgada cuadrada
V Voltios

Introducción

La evaluación de la calidad del punto de soldadura por resistencia mediante un método no destructivo, permite tener una certeza de que todas las piezas cumplen con las características visuales y funcionales necesarias. Además, al establecer una correlación entre las imágenes termográficas y de superficie, con los parámetros de construcción hace posible el determinar si alguno de estos parámetros fue el causante del defecto.

La soldadura por puntos de resistencia (RSW por sus siglas en inglés) es un proceso de manufactura el cual une dos materiales metálicos [3]. Esto se consigue al pasar una alta corriente eléctrica por medio de electrodos, a través de piezas metálicas generando calor que provoca la fusión de estos [4].

Este proceso es ampliamente utilizado en la industria automotriz y aeroespacial, así como en diversas aplicaciones de manufactura, debido a sus bajos tiempos de ciclo, bajo costo de operación, facilidad de implementación y flexibilidad para adaptarse a diferentes combinaciones de materiales como acero, aluminio, titanio, entre otros [3]. Además, el proceso de RSW es conocido por su alta precisión y repetibilidad, lo que garantiza una calidad constante en la producción en serie, permitiendo obtener una unión resistente y duradera entre piezas metálicas.

En el proceso de soldadura por puntos, la calidad de la soldadura depende en gran medida de la precisión y control de los parámetros clave como la corriente que pasa a través de los electrodos, la presión aplicada en los electrodos, y el tiempo de soldado [5]. Debido a que la mayoría de estos parámetros varían durante la formación del punto de fusión, es esencial tener un sistema que monitoree continuamente su evolución durante el proceso [6]. Este monitoreo permite garantizar soldaduras fuertes y duraderas, ya que cualquier variación en los parámetros puede afectar significativamente la calidad de la soldadura.

Existen dos métodos para la evaluación de la calidad del proceso de RSW, los cuales se dividen en pruebas destructivas y pruebas no destructivas. Las pruebas destructivas como jalón, cincel, desprendimiento, y tensión cuantifican la fuerza mecánica que se obtiene de la unión, pero modifican las propiedades físicas de los componentes, por lo que solo se toma un muestreo de las piezas y no al total de las piezas producidas [3, 7]. Estos métodos están definidos por estándares internacionales como lo son el AWS 8.9M-2012 [8], el ISO 15614-12:2021 [9] y el ISO 10447:2015 [10]. Por otra parte, las pruebas no destructivas son la opción preferible en la caracterización de las uniones soldadas, ya que su evaluación no altera permanentemente las propiedades físicas, químicas, mecánicas o dimensionales y pueden aplicarse en cualquier etapa del proceso [11].

Algunas soluciones propuestas para las pruebas no destructivas para determinar la calidad de

la unión han sido la relación de parámetros de entrada como tiempo de soldado, corriente en electrodos, y resistencia eléctrica [2, 12, 6, 5, 13, 14, 15, 16]; la estimación del área de fusión por medio de imágenes termográficas [17, 18, 19, 20, 21] y pruebas de ultrasonido [22]; la clasificación de defectos visuales por medio de imágenes de superficie [23, 24, 7, 4] y el desgaste de los electrodos [25].

el desarrollo y la validación de un banco de pruebas por medio de

El siguiente estudio de investigación se centra en el desarrollo de un banco de pruebas por medio de un transformador de corriente en lugar de una bobina de Rogowski, como se suele utilizar en otros estudios reportados en la literatura, para obtener la medición de corriente. Este banco de pruebas también permite el seguimiento continuo de la fuerza aplicada al sistema durante la formación del punto de soldadura por medio de una celda de carga, el cual permite tener un análisis de los efectos de la fuerza aplicada en el proceso de soldadura por resistencia, la cual solo se caracteriza como un parámetro de entrada y no como una variable continua en el tiempo en trabajos anteriores, por último, el registro de estos parámetros se valida por medio de una verificación de la medición real, contra el valor registrado por los sensores.

1.1. Justificación

Garantizar la calidad de las uniones de soldadura por resistencia es primordial para prevenir posibles riesgos para el usuario final y cumplir las especificaciones visuales, mecánicas y funcionales del producto. Los defectos en estas uniones representan un riesgo importante para el usuario final, sobre todo cuando se utilizan en la fabricación de productos médicos o aeroespaciales, ya que su mal funcionamiento puede provocar repercusiones en la seguridad del usuario final. Además, cualquier queja sobre la calidad provocará un retraso y, potencialmente, un retrabajo o sorteo del material, lo que incrementa los costos de producción.

Las variaciones en la soldadura por puntos pueden afectar tanto la funcionalidad como la seguridad de los productos, que pueden llegar a tener implicaciones severas dentro de la industria de manufactura de productos médicos o la industria aeroespacial. Es por esto, que la identificación de cualquier anomalía en las uniones de manera precisa es indispensable para obtener un producto conformante de acuerdo con las especificaciones establecidas [20].

Existen diferentes estándares internacionales que ayudan a garantizar la calidad en la manufactura, como por ejemplo el ISO 16338 [26], que se enfoca en aplicaciones de la industria aeroespacial que utilizan procesos de soldadura por resistencia, el ISO 13485 [27], que está enfocado en la manufactura de los productos médicos y el estándar AWS D8.9M-2012[8] que define los métodos de prueba en la industria automotriz. Estos estándares garantizan la verificación de los procesos y definen especificaciones funcionales de la evaluación de la calidad como resistencia a la tensión cortante y el tamaño de fusión.

Por lo que métodos que garanticen la calidad y a su vez puedan evaluar características mecánicas de uniones sin alterar las propiedades físicas y mecánicas, es un campo de investigación de suma importancia. Ya que permite realizar una inspección del total de las piezas construidas y garantizar la calidad de estas en las diferentes aplicaciones de manufactura.

La presente investigación, propone una solución basada en los parámetros de entrada como corriente y presión aplicada a los electrodos, tiempo de fusión, y su correlación con imágenes termográficas y digitales para la identificación de defectos visuales y funcionales de la inspección de los puntos de soldadura por resistencia.

Además, permite la predicción de los parámetros del proceso con los cuales fue generada la muestra, tomando la relación entre las características ocultas que presentan las imágenes con respecto a los parámetros de fabricación. Esto permite tener una relación directa entre defectos, su apariencia visual y la distribución de la zona de fusión.

1.2. Descripción del problema

En el proceso de soldadura por resistencia, el comportamiento de los parámetros de ajuste como la corriente que pasa por los electrodos, el tiempo de fusión y la presión de los electrodos tienen un efecto en los aspectos visuales y funcionales, como el diámetro de fusión y la resistencia mecánica, del producto final [3].

Adicionalmente, el proceso de RSW es afectado por una variedad de propiedades del material, como el tipo de material (homogéneos o heterogéneos), porosidad, velocidad de enfriamiento de la unión después de la soldadura, cualquier contaminante en la superficie, la alineación de la soldadura por puntos con el material base, por lo que se requiere documentar estos para tener una base del material utilizado.

Las propiedades de la soldadura se definen principalmente por las variaciones que se producen durante el proceso, donde los parámetros de presión, tiempo de soldado y corriente en electrodos toman un papel fundamental. La aplicación de presión de los electrodos garantiza un contacto adecuado entre las partes soldadas, por otra parte, el tiempo de soldado y la corriente provocan la distribución de la temperatura en la zona de soldadura y crecimiento del punto de fusión [28].

La calidad de los puntos de soldadura por resistencia sigue dependiendo de la inspección visual para detectar productos no conformes, lo que conlleva una baja eficiencia en la detección, un alto tiempo de muestreo, baja precisión, fatiga y es dependiente del estado emocional y la experiencia del evaluador, lo que ocasiona tener una alta tasa de error [4, 29]. Adicionalmente, la detección de defectos en aplicaciones industriales debe tener en cuenta diversos factores, como el cambio de iluminación o el movimiento de los objetos [29].

La inspección visual no puede evaluar las características mecánicas de la unión, por lo cual se tiene que recurrir a diferentes evaluaciones; como dimensiones físicas de la fusión, inspección por ultrasonido y pruebas de resistencia mecánica [3]. Sin embargo, estas se basan en un muestreo de la producción, además de que no generan una retroalimentación inmediata [21].

Por otro lado, los sistemas visuales que evalúan la calidad por medio de imágenes de la superficie tienen limitantes que requieren de condiciones específicas para su buen desempeño, ya que son influenciados por características cambiantes de las cuales se destacan la iluminación, contaminación, o el fondo, por lo que basarse únicamente en este aspecto visual puede conducir a evaluaciones erróneas. Además de ser deficientes en cuanto a la velocidad de procesamiento, las cuales son características necesarias para funcionar eficazmente en un entorno de producción [21, 19].

Otro aspecto importante que influye en la calidad es la distribución del punto de fusión en una soldadura. Esta distribución de calor que ocurre durante el proceso desempeña un papel importante para determinar la resistencia de la fusión. Si la distribución de calor no es uniforme, se tiene una inconsistencia en el proceso, lo que puede comprometer su integridad estructural.

Es necesario comprender los factores interrelacionados y sus efectos, que requieren una supervisión y control del proceso de soldadura para garantizar resultados óptimos y repetibles. Por lo que la relación entre la apariencia visual, la distribución de calor y los parámetros de construcción de las muestras plantea un reto complejo a la hora de predecir y categorizar la calidad de la soldadura.

1.3. Estructura de Tesis

La tesis está organizada del siguiente modo:

- El capítulo 2 se muestran los antecedentes del presente proyecto, en este se presentan trabajos que relacionan los parámetros de entrada con el desempeño funcional, la estimación del área de fusión por medio de la obtención de imágenes termográficas y pruebas de ultrasonido, y la clasificación de defectos visuales por medio de imágenes de la superficie, entre otros.
- En el capítulo 3 se plantea la fundamentación teórica utilizada en el presente trabajo, donde se describe el proceso de soldadura por resistencia, los aspectos fundamentales de la calidad, los métodos de procesamiento de las imágenes y los algoritmos utilizados para la clasificación y predicción de la calidad, así como las métricas de evaluación utilizadas en estos modelos.
- El capítulo 4 se establece la hipótesis del presente trabajo.
- El capítulo 5 se establecen el objetivo general y objetivos específicos del presente proyecto.
- El capítulo 6 se aborda la metodología seguida para el presente proyecto, el cual consta de la integración de un banco de pruebas para el registro de los parámetros de corriente que pasa a través de los electrodos, fuerza de los electrodos y tiempo de ciclo. La construcción de las muestras basado en el estándar AWS D8.9. El procesamiento de las imágenes y la descripción de la base de datos generada. Por último, el desarrollo del modelo clasificador y predictor de la calidad del punto de fusión.
- En el capítulo 7 se presentan los resultados obtenidos.
- El capítulo 8 se presentan las conclusiones del presente trabajo, así como posibles trabajos futuros en base al trabajo de investigación actual.

Antecedentes

Se analizan diversos trabajos de investigación relacionados con la evaluación de los procesos de soldadura. Los artículos abarcan una serie de métodos para supervisar y evaluar la calidad y las características de la soldadura por puntos de resistencia. Estos métodos incluyen el uso de parámetros de construcción (principalmente eléctricos), imágenes termográficas, pruebas ultrasónicas e imágenes de superficie, proporcionando una visión completa de los distintos enfoques y métodos de investigación utilizados para evaluar los procesos de soldadura por puntos de resistencia. Así como también los distintos modelos utilizados para supervisar y analizar los procesos de soldadura, como el uso de redes neuronales y algoritmos de aprendizaje automático para predecir la resistencia mecánica o clasificar la calidad de la soldadura. Otros utilizan imágenes termográficas para estimar el área de fusión o analizar la calidad superficial de las soldaduras.

En el trabajo [2], se presentó un dispositivo de monitoreo de parámetros eléctricos para registrar el voltaje, la corriente, la potencia y la resistencia durante la soldadura por puntos utilizando un sensor de efecto Hall. Los datos obtenidos mediante esta técnica se analizaron para comprender los fenómenos que se producen durante la formación del punto de fusión.

En [12], se muestra un enfoque similar utilizando una red neuronal para predecir la resistencia al esfuerzo cortante utilizando parámetros como la corriente, la fuerza, el tiempo y la resistencia dinámica como entrada de la red neuronal para la predicción de esfuerzo cortante.

En [6] se desarrolló un prototipo para monitorear la calidad de las uniones soldadas utilizando los parámetros de corriente, voltaje, fuerza del electrodo y un sensor acústico para predecir el diámetro de la soldadura, la resistencia mecánica y la aparición del fenómeno de salpicaduras del metal.

En el trabajo [5], se investigó la viabilidad de la soldadura de dos materiales: Quemado y partición (Q&P por sus siglas en inglés) y Plasticidad inducida por la transformación (TRIP por sus siglas en inglés). Se evaluaron los efectos de parámetros de entrada como la corriente, el voltaje, la resistencia eléctrica y la presión del electrodo en relación con propiedades mecánicas como la resistencia mecánica. Se determinó que los parámetros clave que influyen en la calidad de la soldadura son la corriente de soldadura, la fuerza del electrodo y el tiempo de soldadura.

En [13], utilizó un modelo de bosques aleatorios (en inglés, Random Forest) para clasificar la calidad de la soldadura en tres categorías (soldaduras frías, expulsión y soldaduras buenas) mediante la captura de parámetros eléctricos como el voltaje, la corriente y el cálculo de la resistencia dinámica.

En [14], propone métodos de estimación de la calidad de la soldadura utilizando la corriente,

tensión y resistencia dinámica que se obtienen durante el proceso en tiempo real, las cuales transforma a imágenes y posteriormente procesa por medio de una red neuronal convolucional (CNN por sus siglas en inglés). Los datos de tensión, corriente y fuerza de sujeción se obtuvieron mediante el uso de sensores durante el proceso de soldadura, y la resistencia dinámica se calculó de acuerdo a los valores instantáneos de la tensión según el periodo de muestreo del sensor durante el ciclo.

De manera similar en [15], se propuso un sistema de detección en tiempo real de la corriente y el voltaje. Las señales de corriente se analizaron para caracterizar la calidad de la soldadura, la cual se clasificó en tres categorías: soldaduras malas, soldaduras buenas y soldaduras de salpicaduras del metal. Estas señales se utilizaron como entradas para una red neuronal artificial y un modelo de regresión para la clasificación del punto de soldadura.

Por último, [16] monitorea los parámetros de corriente y voltaje para determinar la resistencia mecánica, adicionalmente explora la relación entre la presión de los electrodos y su influencia en la resistencia dinámica de la pieza. Determina que el pico inicial de la resistencia dinámica se ve afectado por la presión de los electrodos. Finalmente utiliza dos modelos de regresión y una red neuronal para predecir el diámetro de fusión a partir de la resistencia dinámica, esta pasa por un proceso de análisis de componentes principales (PCA por sus siglas en inglés) para reducir su dimensionalidad y reducir el costo computacional.

Las propuestas revisadas utilizan una bobina Rogowski, la cual es una opción popular para medir corrientes en aplicaciones de alta potencia. Sin embargo, estas bobinas son susceptibles a campos magnéticos externos, lo que afecta la precisión de la medición, en comparación, los transformadores de corriente como el que se propone en el presente trabajo son resistentes a interferencias magnéticas externas [30], lo que los hace una opción más confiable en entornos con alta actividad electromagnética. Además, las bobinas de Rogowski pueden presentar problemas en aplicaciones de alta frecuencia, lo que limita su versatilidad y precisión en este tipo de escenarios. Adicionalmente, requieren de un circuito integrador para convertir la señal, lo que aumenta la complejidad del sistema.

En cuanto al registro de la fuerza de los electrodos, en los trabajos presentados solo se registra el parámetro de fuerza como un parámetro de entrada. Aunque esto puede ser útil para registrar la fuerza aplicada, no se registran las mediciones de fuerza de los electrodos durante el proceso. Además, el registro de la fuerza durante la operación proporciona información valiosa sobre la distribución de la fuerza en la muestra.

Otros autores, se enfocan en la adquisición y procesamiento de imágenes termográficas para la estimación del área de fusión. En [17], utiliza imágenes termográficas para determinar el diámetro de fusión, utilizando los gradientes de color para el cálculo de la dimensión y verificando con una inspección visual obteniendo una diferencia de 22 % con respecto a la medida real del punto de fusión.

En [18] se realizó un estudio para evaluar la influencia de la polaridad en una máquina de soldadura por resistencia adaptándola para registrar los parámetros de tensión y corriente utilizando una bobina Rogowski, así como el registro de la temperatura mediante una cámara termográfica. Se realizaron comparaciones entre las dos polaridades en cuanto al aspecto de la superficie, el diámetro de fusión y una prueba jalón para registrar los modos de fallo interfacial (en inglés, interfacial failure) que ocurre cuando se tiene una rotura en la zona de la soldadura, o modo de fallo por desprendimiento (en inglés, pull-out failure) donde la rotura ocurre en el material base adyacente a la zona de fusión.

En [19] propone dos métodos de inspección del proceso de RSW por medición de imágenes

termográficas, la primera permite una inspección durante el proceso y en la segunda aplica calor a las placas después del proceso de soldado para medir el diámetro de fusión. La precisión de la medición durante el proceso es de ± 0.5 mm, mientras que la medición posterior al proceso tiene una precisión de ± 0.1 mm.

En [20] utiliza una CNN para la clasificación de la calidad de la soldadura por resistencia, donde define las categorías de la calidad en malas a las que presentan un fallo interfacial (IF), aceptables a las que presentan un fallo por desprendimiento (PF) pero presentan porosidad, y buenas en las que no se presenta porosidad.

En [21], presenta un modelo para la evaluación del proceso RSW por medio de una cámara termográfica utilizando redes neuronales convolucionales, para predecir el tamaño y forma del área de fusión. El modelo consta en dos pasos, el primero consiste en reducir el ruido de los videos tomados por una cámara termográfica, y el segundo en desarrollar un modelo CNN 2D para detectar el momento de inicio efectivo de cada video y el centro de la soldadura para la segmentación y la detección del tamaño de la soldadura. También identificó que la principal razón de las variaciones es la propiedad de reflexión de los materiales de soldadura disímiles.

La prueba por ultrasonido es el método más utilizado para la inspección de las soldaduras por puntos en la industria automotriz, pero su precisión depende de la habilidad del usuario [7]. En [22], propuso la implementación de árbol de clasificación y regresión (CART por sus siglas en inglés) y bosque aleatorio, como herramientas de reconocimiento de patrones para la clasificación de pruebas por ultrasonido en el proceso de RSW. Clasifica las fusiones en 4 categorías: bueno, corto, debajo del tamaño y sin soldadura.

Otro enfoque popular en la evaluación del proceso de soldadura es el análisis de la superficie en base a sistemas de visión y procesamiento de imágenes, para determinar la calidad superficial del proceso [7], además de que estos defectos contienen características que se relacionan con el desempeño mecánico de la unión.

En [23] establece una relación entre la densidad de un objeto en un espacio la cual define como dimensión fractal, y la resistencia mecánica por una prueba de jalón. Para esto utiliza un procesamiento de imágenes de superficie, para diferenciar entre el punto de soldadura y el fondo. Tomando en cuenta la densidad del punto de fusión calcula la dimensión fractal. Determina una correlación entre la dimensión fractal y la resistencia mecánica, esto debido a que mientras aumenta la dimensión fractal, también su resistencia mecánica.

En [24], propone un algoritmo de CNN, utilizando el rastro de calor en una imagen de la superficie de la soldadura para predecir la fuerza de jalón, el diámetro de la fusión y el modo de fractura. Sin embargo, requirió controlar condiciones como iluminación, distancia y ángulo de la imagen para hacer una predicción precisa. Además, debido a que el rastro de calor en superficie depende de las condiciones de transferencia de calor, aspectos como contaminación de los electrodos y la desalineación de estos afecta su apariencia superficial.

En [7], propone un modelo de red ligera MobileNetV3 para la detección de posición y la calidad de la soldadura por puntos. Además, introduce una técnica de aumento de datos para el proceso de entrenamiento, la cual organiza aleatoriamente cuatro imágenes en una sola y evalúa las cuatro imágenes a la vez, haciendo que el entrenamiento de la red sea más robusto.

En [4], propone un modelo CNN multiescala con mecanismo de atención denominado AcmNet para la clasificación de puntos de soldadura en siete tipos: 1) Normal, 2) Adherencia del cobre, 3) Borde, 4) Sobrepuesto, 5) Mutilación, 6) Salpicadura y 7) Torcedura.

Por otra parte, [31] propone un algoritmo mejorado para la localización de puntos de soldadura

basado en el método de detección de círculos asistida por ángulo (AACD por sus siglas en inglés), el cual se basa en la transformada de Hough para reducir la complejidad computacional y mejorar la respuesta en tiempo. Este algoritmo se comparó con otros métodos de detección de círculos, como librerías de acceso libre de OpenCV, Transformación aleatoria de Hough (RHT por sus siglas en inglés) y la detección aleatoria de círculos (RCD por sus siglas en inglés).

En [32], propone el modelado del proceso de soldadura por resistencia definido por los procesos térmicos, mecánicos y metalúrgicos acoplados que se producen durante el proceso. Este modelo es probado en un software comercial de simulación de soldadura por resistencia SYSWELD[®]. En su estudio evalúa la sensibilidad de los datos de entrada eléctricos y térmicos mediante variaciones de +/-5%, a excepción de la resistencia eléctrica de contacto, la cual se elevó a +/-20% ya que se considera que es el factor más significativo que influye en la geometría de la fusión como diámetro y altura relativa de penetración.

Por último, [25] se enfoca en la calidad de los electrodos de soldadura, los cuales desempeñan un papel importante en la repetibilidad del proceso de RSW. Su estudio se basa en determinar el desgaste de la punta del electrodo provocado por múltiples repeticiones del proceso. Para determinar el desgaste toma imágenes del electrodo y utiliza técnicas de segmentación de imágenes para evaluar su estado.

En la Tabla 2.1, se muestran los modelos utilizados en el estado del arte, así como también los diferentes resultados de la evaluación.

Tabla 2.1: Resumen de antecedentes

Autor	Modelo	Evaluación	Oportunidades	Resultados
[22]	Árbol de clasificación y regresión y bosque aleatorio	Prueba de ultrasonido para la clasificación del tamaño de soldadura en 4 tamaños de fusión	Las mediciones por ultrasonido son susceptibles a la desalineación, adicionalmente no considera características visuales para la evaluación	96 % Exactitud
[12]	Red neuronal artificial	Parámetros de entrada para predecir el esfuerzo cortante	La evaluación de la calidad no incluye ningún defecto visual	MSE 0.054 95 % Exactitud
[13]	Bosques aleatorios	Señal de resistencia dinámica para la clasificación de la calidad de la soldadura en soldaduras buenas, frías y salpicaduras	La evaluación de la calidad no incluye ningún defecto visual	93.6 % Exactitud
[24]	CNN	Imágenes de superficie para predecir el esfuerzo cortante, diámetro de fusión y el modo de fractura	Requiere del control de condiciones como iluminación, distancia y ángulo de la imagen para hacer una predicción precisa	cortante R^2 0.9943 diámetro R^2 0.9857 98.8 % Exactitud

Tabla 2.1: Resumen de antecedentes

Autor	Modelo	Evaluación	Oportunidades	Resultados
[14]	CNN GoogleNet	Parámetros de RSW para la clasificación de la calidad	Evalúa aspectos visuales sin determinar el tipo de defecto, ni considerar características funcionales	90 - 98 % Exactitud
[15]	Red Neuronal y modelo de regresión	Señales de potencia para la clasificación de la calidad en bueno, malo y salpicaduras	La evaluación de la calidad no incluye ningún defecto visual	Regresión MAE 0.0524 Red Neuronal MAE 0.02593
[20]	CNN	Imágenes termográficas para clasificación en soldaduras buenas, aceptables y malas	No considera características funcionales de la calidad	97.33 % Exactitud
[16]	Extreme learning machine (ELM)	Relación entre corriente y tiempo de soldado contra el diámetro de fusión	La evaluación de la calidad no incluye ningún defecto visual	RSME 0.0874 MAE 0.0718 MSE 0.0076 MAPE 4.672 % R^2 0.9611
[7]	CNN MobileNet	Imágenes de superficie para la clasificación de la calidad en bueno y malo	Evalúa aspectos visuales sin determinar el tipo de defecto, ni considerar características funcionales	82.93 % Exactitud
[21]	2D y 3D CNN	Videos termográficos para la clasificación de 5 tamaños de fusión	Se requiere realizar una conversión de la forma predicha para determinar si el diámetro es aceptable	84 - 92 % F1 score
[4]	CNN AcmNet	Imágenes de superficie para clasificación de defectos visuales	Únicamente evalúa aspectos visuales, sin considerar características funcionales	95.2 % Exactitud 94.14 % Sensitividad 93 % Precisión 93.28 % F1 score

2.1. Proceso de Soldadura por Resistencia (RSW)

Su principio es aplicar una gran corriente entre dos electrodos y piezas metálicas, lo que provoca que las dos piezas se fusionen bajo la acción combinada de la presión y el calor [4]. Donde la aplicación de presión de los electrodos garantiza un contacto adecuado entre las partes soldadas, y la generación de calor se consigue por el principio físico de la ley de Joule, que en su forma más simple puede expresarse mediante la ecuación 2.1 [28].

$$H = I^2 R t \quad (2.1)$$

Donde H es la energía térmica en Joules, I es la corriente en amperes, R es la resistencia en ohms, y t es el tiempo en segundos.

En consecuencia, la generación de calor durante el proceso de soldadura está relacionada con las mediciones de la calidad de la soldadura, como el tamaño de fusión. Por lo tanto, los parámetros de soldadura más importantes que determinan una unión efectiva son el tiempo de soldado, corriente de soldado y fuerza de los electrodos [32].

La Figura 2.1 muestra una representación visual de estos parámetros y su comportamiento durante el proceso.




Figura 2.1: Secuencia del proceso de soldadura por puntos, adaptada de [1].

2.1.1. Fuerza de los electrodos (en inglés, Electrode Force)

La fuerza del electrodo se utiliza para presionar los componentes durante el proceso de soldado. Esta debe ser lo suficientemente fuerte para superar la deformación del material y así tener un contacto óptimo antes de que fluya la corriente.

2.1.2. Corriente de soldadura (en inglés, Weld Current)

La cantidad de corriente eléctrica utilizada durante la soldadura. Se aconseja mantener la corriente de soldadura lo más baja posible de acuerdo con cada aplicación. Si la corriente de soldadura es demasiado alta, se producirán salpicaduras y los electrodos pueden quedar pegados al material. La corriente en el proceso de soldadura por resistencia se encuentra en el rango de los miles de amperes [4], esta varía dependiendo de diferentes factores como el tipo de material, espesor de los componentes, tiempo de ciclo aplicado, entre otros. Un método para determinar un rango de aceptables es por medio de las curvas Lobe (Figura 2.2) [2].

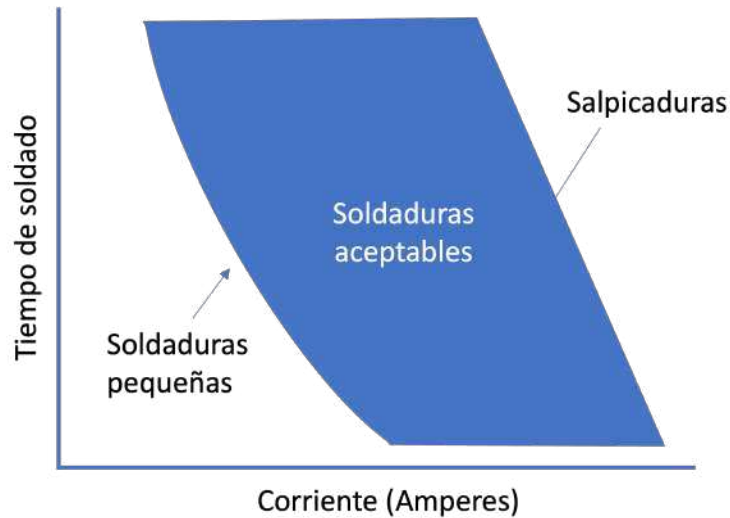


Figura 2.2: Curva Lobe de soldadura por resistencia, adaptada de [2].

2.1.3. Tiempo de soldado (en inglés, Weld Time)

Es el tiempo en el que se aplica la corriente eléctrica a las piezas por medio de los electrodos generando el punto de fusión. Adicionalmente se tienen el tiempo de compresión que sirve para estabilizar la fuerza aplicada a las piezas antes de aplicar la corriente, y el tiempo de espera que es después del soldado y es necesario para que la soldadura se solidifique antes de soltar las piezas.

2.2. Evaluación de la calidad

Existen diferentes estándares que definen la calidad de la soldadura por resistencia, dentro de los cuales se puede evaluar en tres características esenciales, 1) la inspección visual de la pieza, 2) el diámetro de fusión, y 3) la resistencia mecánica. Estas pruebas están basadas en estándares internacionales como AWS D8.9M-2012 [8], el ISO 15614- 12:2021 [9] y el ISO 10447:2015 [10], los cuales describen los parámetros de prueba como la velocidad, preparación de los especímenes, distancia entre mordazas, entre otros.

La prueba de jalón (Figura 2.3a) y desprendimiento (Figura 2.3b) cuantifican la fuerza que soporta la unión [3, 7].

Sin embargo [3], determina que el diámetro de fusión medido tiene una mayor correlación con la prueba de jalón, en comparación con la prueba de desprendimiento (Figura 2.4).



(a)



(b)

Figura 2.3: Pruebas de jalón (a) y desprendimiento (b), adaptada de [3].

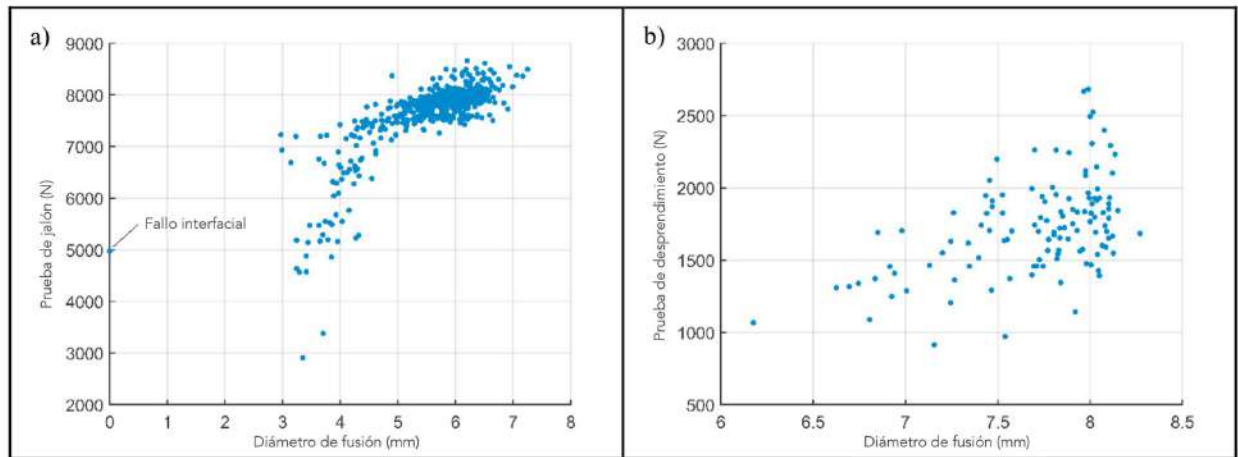


Figura 2.4: Relación de prueba de jalón y desprendimiento con diámetro de fusión, adaptada de [3].

En cuanto a el tamaño de la fusión, existen diferentes evaluaciones como la recomendada por la Asociación Americana de Soldadura (AWS por sus siglas en inglés), en el estándar D8.9M-2012 [8] se define el diámetro de fusión crítico por la ecuación 2.2.

$$d = 4\sqrt{t} \quad (2.2)$$

Donde d es el diámetro de fusión, y t el espesor del material.

Otros autores proponen diferentes modelos para calcular el diámetro crítico de fusión, En [33], define el diámetro crítico por la ecuación 2.3.

$$D = 3,41(t)^{(4/3)} \quad (2.3)$$

Donde t es el espesor del material.

En [34], propone la ecuación 2.4, para garantizar el modo de fallo por desprendimiento.

$$D > \frac{3,2t}{f} \quad (2.4)$$

Donde f es el factor de porosidad de la soldadura, que depende de las propiedades de la soldadura, como la porosidad y la irregularidad.

Existen algunas características que pueden observarse en la superficie de un punto de soldadura, como la forma (círculo), la zona interior del punto de fusión, el círculo exterior que se forma en la zona afectada por el calor de la fusión. Las salpicaduras situadas cerca y fuera del contorno exterior. Las hendiduras interiores que indican la existencia de huecos o grietas dentro de la zona de fusión [35].

Fundamentación teórica

En la presente sección se incluye información sobre el procesamiento de imágenes, las redes neuronales convolucionales y las métricas de evaluación utilizadas en los modelos de clasificación y predicción.

3.1. Procesamiento de imágenes

Los puntos de soldadura con propiedades mecánicas deficientes suelen ir acompañados de apariencias defectuosas, por lo que algunos problemas de puntos de soldadura pueden encontrarse a tiempo mediante el reconocimiento de la apariencia superficial [4]. Además, en el proceso de RSW, la forma de la soldadura y el rastro de calor alrededor de la superficie provocado a la elevada corriente tiene un efecto importante en la calidad de esta, ya que puede correlacionarse cuantitativamente con el tamaño de la fusión [19]. Cuanto mayor sea la entrada de calor y la fusión, mayor será el alcance de la marca de calor y más profunda será la profundidad de la hendidura [24].

Por otro lado, las cámaras termográficas detectan la radiación en el rango infrarrojo del espectro electromagnético (aproximadamente entre 9.000 y 14.000 nanómetros o 9-14 μm), y producen imágenes de esa radiación llamadas termogramas. Existen dos tipos de fuente de calor: la primera es de tipo pasivo, que consiste en determinar la energía de radiación del objeto, y la otra es de tipo activo, que consiste en determinar la energía de radiación después de que se le aplique una fuente de calor externa al objeto [17]. Los sistemas de inspección basados en la termografía tienen el inconveniente que el punto de fusión se encuentra obstruido mientras el electrodo está en contacto con el material, por lo que no se pueden obtener datos precisos durante este periodo, y al momento en el que el electrodo se separa de los materiales, el punto de fusión se encuentra en una etapa de enfriamiento, por lo que es necesario encontrar el primer momento en el que se puede observar la fusión de soldadura para minimizar el error de los datos [21]. Adicionalmente, la temperatura reflejada, y el coeficiente de atenuación toman un papel importante para obtener una alta precisión en los valores de temperatura medidos por la cámara termográfica [36].

Las imágenes termográficas muestran las áreas de alta temperatura en un rango que va desde el color azul en la zona más fría, hasta el color rojo donde se tiene la zona con más calor. Estas imágenes también muestran la dispersión del calor en el punto de fusión y por consiguiente, están relacionadas directamente formación y calidad de la soldadura.

Las imágenes de soldadura por puntos obtenidas por una cámara suelen tener una amplia resolución, y el punto de soldadura en la imagen sólo ocupa una pequeña parte del área total. Por

lo tanto, se requieren procesar estas imágenes para detectar regiones específicas. Una alta calidad de las imágenes es una condición esencial para los pasos posteriores de segmentación y medición. Las imágenes digitalizadas deben permitir una clara distinción entre la zona de soldadura y el material de base [23].

Existen diferentes métodos para la preparación de las imágenes y la segmentación de estas. Un ejemplo es la segmentación por umbral, donde asume que el objetivo y el fondo de la imagen tienen una distribución de gris desigual, lo que significa que el valor de gris entre los píxeles adyacentes dentro del objetivo y el fondo es muy relevante, ya que el valor de gris del píxel del objetivo y el fondo es muy diferente. Si la imagen sólo tiene dos áreas de valor de gris, se puede aplicar la segmentación por umbral a un valor de gris que divide el fondo de la zona de objeto; si la imagen contiene múltiples áreas de valor de gris, se definen una serie de umbrales para segmentar cada rango [37]. Otro método es evaluar la imagen por medio de un histograma según el valor de los píxeles. Donde la zona objetivo en el histograma suele tener un valor diferente al del fondo, por lo que, asignando un valor de gradiente del píxel, puede obtenerse la zona requerida [37].

3.2. Redes Neuronales Convolucionales (CNN)

En el proceso de soldadura por resistencia, existen defectos típicos que pueden ser detectados visualmente a partir de imágenes, en base a las características de esta, por lo que pueden evaluarse mediante modelos de aprendizaje profundo [7]. Las redes neuronales convolucionales de aprendizaje profundo han mostrado excelentes efectos en tareas visuales debido a su potente capacidad de extracción de características [4].

La aplicación más exitosa del aprendizaje profundo es el aprendizaje supervisado, que utiliza muestras etiquetadas para aprender relaciones complejas. Utilizando un conjunto de datos de soldaduras por puntos etiquetadas, los modelos de aprendizaje profundo permiten aprender características complejas que pueden utilizarse para la inspección de la calidad del proceso de soldadura [7]. El aprendizaje profundo requiere que el modelo aprenda y comprenda patrones en los datos, lo que convierte al aprendizaje profundo en una herramienta increíblemente potente para resolver problemas complejos como es el relacionar imágenes de superficie o termográficas con los parámetros de calidad como diámetro de fusión, inspección visual y fuerza de jalón, así como también sus parámetros de construcción.

Existen diferentes algoritmos y estructuras que están especializadas para la detección y clasificación de objetos, como Mask R-CNN [38], Fast R-CNN [39], Faster R-CNN [40], SSD [41] y YOLO [42], que son algoritmos de detección de objetos, los cuales delimitan cada objeto en cajas de acuerdo con la probabilidad de pertenecer a una clase asociada. Así mismo se encuentran estructuras como TensorFlow que tiene un módulo de detección de objetos.

El aumento de datos desempeña un papel importante para aumentar la estabilidad y la respetabilidad de la detección [29]. Existen diferentes métodos de aumento de datos como los utilizados en [20], donde genera nuevas imágenes al girar la imagen original, rotarla, aumentarla o modificar el espacio de color; o en [7], donde une aleatoriamente cuatro imágenes en una sola, y evalúa las cuatro imágenes a la vez, haciendo que el entrenamiento de la red sea más robusto y evitar problemas de sobreajuste.

3.3. Análisis de los resultados

3.3.1. Validación cruzada

La validación cruzada es una técnica que utiliza diferentes particiones y calcula los resultados promediando las rondas. Donde los datos originales se dividen aleatoriamente en k subconjuntos de igual tamaño, se utilizan $k-1$ subconjuntos para entrenar y los datos restantes para probar. El proceso se rota k veces y los resultados se promedian [22]. Esto permite tener la evaluación del modelo con diferentes grupos de entrenamiento y validación, por lo que el promedio de estos da un valor de la variación de la efectividad del modelo.

3.3.2. Correlación de Pearson

La correlación de Pearson es una medida estadística que evalúa la relación lineal entre dos variables continuas. Esta determina el grado de asociación siendo 1 una asociación positiva entre dos variables, -1 una asociación negativa entre dichas variables y un valor cercano a 0 si las variables no presentan una relación lineal entre si [43].

3.3.3. Métricas datos categóricos

Las métricas más utilizadas en datos categóricos son la tasa de clasificación (ecuación 3.1), y la tasa de error (ecuación 3.2).

$$\text{Tasa de clasificación} = \frac{\text{clasificación correctas}}{\text{total de predicciones realizadas}} \quad (3.1)$$

$$\text{Tasa de error} = \frac{1 - \text{clasificación incorrectas}}{\text{total de predicciones realizadas}} \quad (3.2)$$

Sin embargo, para comprender mejor cada uno de los posibles resultados dentro de la clasificación (TP, TN, FP, FN) se utiliza la matriz de confusión.

3.6.2.1 Matriz de confusión

- Verdadero positivo (TP): Se espera un valor positivo y se predice un valor positivo.
- Verdadero negativo (TN): Se espera un valor negativo y se predice un valor negativo.
- Falso positivo (FP): Se espera un valor negativo y se predice un valor positivo.
- Falso negativo (FN): Se espera un valor positivo y se predice un valor negativo.

3.6.2.2 Exactitud

Es la métrica que describe el rendimiento del modelo en todas sus clases [44]. Es útil cuando todas las clases tienen la misma importancia. Esta se define por la ecuación 3.3.

$$\text{Exactitud (accuracy)} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3.3)$$

3.6.2.3 Precisión

Es la capacidad de modelo en clasificar alguna predicción como positiva [44]. Esta se define por la ecuación 3.4.

$$\text{Precisión} = \frac{TP}{(TP + FP)} \quad (3.4)$$

3.6.2.4 Recall

Mide la capacidad del modelo para detectar instancias positivas [44], mientras más alto el recall, más instancias positivas han sido detectadas. Esta se define por la ecuación 3.5.

$$\text{Sensitividad (recall)} = \frac{TP}{(TP + FN)} \quad (3.5)$$

3.6.2.5 FBeta score

Se puede definir como la media armónica entre recall y precisión [44], donde F1 es un balance entre falsos positivos y los falsos negativos. Fbeta-Score (F1, en este caso) se calcula por la ecuación 3.6.

$$F1 = \frac{(2 * TP)}{(2 * TP + FP + FN)} \quad (3.6)$$

3.3.4. Métricas datos continuos

Para la evaluación de datos continuos existen diferentes métricas de error como las siguientes:

3.6.3.1 Error medio cuadrático (MSE Y RMSE)

Es el método más comúnmente utilizado para predecir el error. También se utiliza su raíz cuadrada RMSE [45, 46]. Estas se definen por las ecuaciones 3.7 y 3.8.

$$MSE = \frac{\sum_{i=1}^n (p_i - a_i)^2}{N} \quad (3.7)$$

$$MSE = \sqrt{\frac{\sum_{i=1}^n (p_i - a_i)^2}{N}} \quad (3.8)$$

Donde p_i es el valor predicho y a_i es el valor real

3.6.3.2 Error medio absoluto (MAE)

Es una medida que solo promedia las magnitudes de cada error de manera individual, sin tener en cuenta su signo [45, 46]. Esta se define por la ecuación 3.9.

$$MAE = \frac{\sum_{i=1}^n |p_i - a_i|}{N} \quad (3.9)$$

3.6.3.3 Error relativo absoluto y cuadrático (RAE y RSE)

El error absoluto relativo se calcula tomando en cuenta el error absoluto total y dividiéndolo por la diferencia absoluta entre la media y el valor real mediante la ecuación 3.10. Por otro lado, el error relativo cuadrático devuelve un valor entre [0-1], muestra la suma cuadrada de las diferencias entre el valor predicho y el valor real, calculándose en base a la ecuación 3.11 [47, 46].

$$RAE = \frac{\sum_{i=1}^n |p_i - a_i|}{\sum_{i=1}^n |a_i - a|} \quad (3.10)$$

$$RSE = \frac{\sum_{i=1}^n (p_i - a_i)^2}{\sum_{i=1}^n (a_i - a)^2} \quad (3.11)$$

Donde p_i es el valor predicho, a_i es el valor real y a es el promedio.

3.6.3.4 Coeficiente de correlación (CC)

El coeficiente de correlación calcula la correlación entre los valores actuales y los valores predichos. Este varía entre [0-1], donde 0 se interpreta sin correlación y 1 una correlación perfecta [46]. Se calcula por medio de la ecuación 3.12.

$$CC = \frac{S_{PA}}{\sqrt{S_P * S_A}} \quad (3.12)$$

Donde:

$$S_{PA} = \frac{\sum_{i=1}^n (p_i - p)(a_i - a)}{n - 1}$$
$$S_P = \frac{\sum_{i=1}^n (p_i - p)^2}{n - 1}$$
$$S_A = \frac{\sum_{i=1}^n (a_i - a)^2}{n - 1}$$

3.6.3.5 Coeficiente de determinación (R^2)

El coeficiente de determinación calcula el cuadrado del coeficiente de correlación de Pearson. Se obtiene la variación de la variable predictora Y que es explicada por la variable X . con mayor proporción (mayor coeficiente de determinación), mejor será la predicción. Si el coeficiente de determinación es igual a 1, la variable predictora explica toda la variación en Y , por lo que no hay error en la predicción [48]. Esta se calcula en base a la ecuación 3.13.

$$R^2 = \frac{SS_{reg}}{SS_{tot}} \quad (3.13)$$

Donde:

$$SS_{reg} = \sum_{i=1}^n (y_i - P_i)^2$$
$$SS_{tot} = \sum_{i=1}^n (y_i - Y_{mean})^2$$

Hipótesis

La aplicación de modelos de redes neuronales convolucionales permite establecer una correlación entre las variaciones de los parámetros del proceso como corriente, tiempo y la presión de los electrodos, y las alteraciones del material capturadas mediante imágenes obtenidas a partir de un sistema de visión, dando lugar a una mayor precisión en la detección de defectos en las uniones soldadas y permite predecir una estimación del desempeño funcional de la fusión, permitiendo una inspección no destructiva.

Objetivos

5.1. Objetivo General

Determinar la calidad del proceso de soldadura por puntos a través de modelos de redes neuronales convolucionales, estableciendo una relación entre los parámetros de proceso, su apariencia superficial y distribución de calor en la zona de fusión por medio imágenes adquiridas por un sistema de visión, para la clasificación y predicción de la calidad de la fusión.

5.1.1. Objetivos específicos

Los objetivos específicos de este proyecto son los siguientes:

- Construir un banco de pruebas mediante la instrumentación de un equipo de soldadura por resistencia, para determinar la variabilidad de los parámetros de entrada y su influencia contra la salida.
- Generar base de datos, mediante la obtención de datos de parámetros de entrada e imágenes procesadas, para la evaluación del modelo de análisis.
- Evaluar la calidad de la soldadura por resistencia, por medio de la correlación de parámetros de entrada y salida, para la identificación de alteraciones en el material.
- Verificar la efectividad del modelo, por medio de una validación cruzada y una precisión mayor o similar al estado del arte, para mejorar la exactitud en la detección de defectos en uniones soldadas.

Metodología

La metodología aplicada en el presente trabajo (Figura 6.1) consiste en la integración de un banco de pruebas con el fin de estudiar el impacto de los parámetros de entrada en la salida, crear una base de datos para el análisis y el entrenamiento de los modelos de inteligencia artificial, evaluar la calidad de la soldadura y probar la eficacia del modelo para detectar defectos en las uniones soldadas.

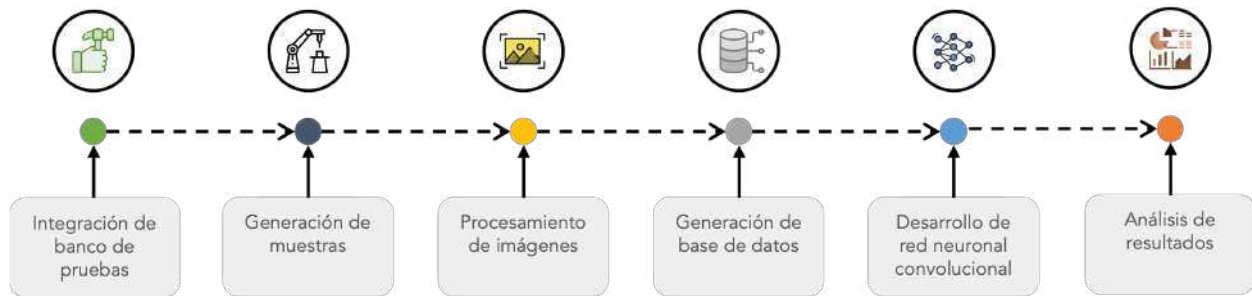


Figura 6.1: Metodología general del proyecto.

6.1. Integración de banco de pruebas

La instrumentación del banco de pruebas (Figura 6.2) se diseñó y construyó como parte del proyecto de investigación. Esta consta de una soldadura por resistencia manual, que utiliza la plataforma Arduino UNO como controlador del sistema y regula el tiempo de ciclo del proceso. Se incluye un pistón neumático de doble efecto, que regula la fuerza de los electrodos aplicada al sistema. Por último, registra el parámetro de corriente mediante el uso de un transformador de corriente y el parámetro de fuerza de los electrodos por medio de una celda de carga [49].




Figura 6.2: Banco de pruebas.

El microcontrolador Arduino UNO controla el sistema del banco de pruebas por medio de un programa escrito en el lenguaje de programación C++. En este se asignan los valores de tiempo de compresión, y tiempo de soldado.

La secuencia del programa (Figura 6.3) comienza con proceso de calibración de los sensores de fuerza y corriente utilizando las librerías “HX711_ADC.h” y “ACS712.h” respectivamente. A continuación, el programa espera a que el usuario presione el botón de inicio, transmitiendo una señal a una entrada digital del Arduino UNO. Seguido de esto activa la salida digital conectada a un relevador, que hace un cambio de estado en la electroválvula y activa el cilindro neumático, espera 1000ms (tiempo de compresión) y procede a activar la salida digital del relevador que activa la máquina de soldadura por resistencia. El programa adquiere e imprime los valores de los sensores de corriente y presión de los electrodos hasta que transcurre el tiempo de ciclo establecido (tiempo de soldado). Por último, desactiva la salida digital conectada al relevador de la máquina de soldadura, seguido de la desactivación de la salida digital del relevador conectado a la electroválvula que desactiva el cilindro neumático.

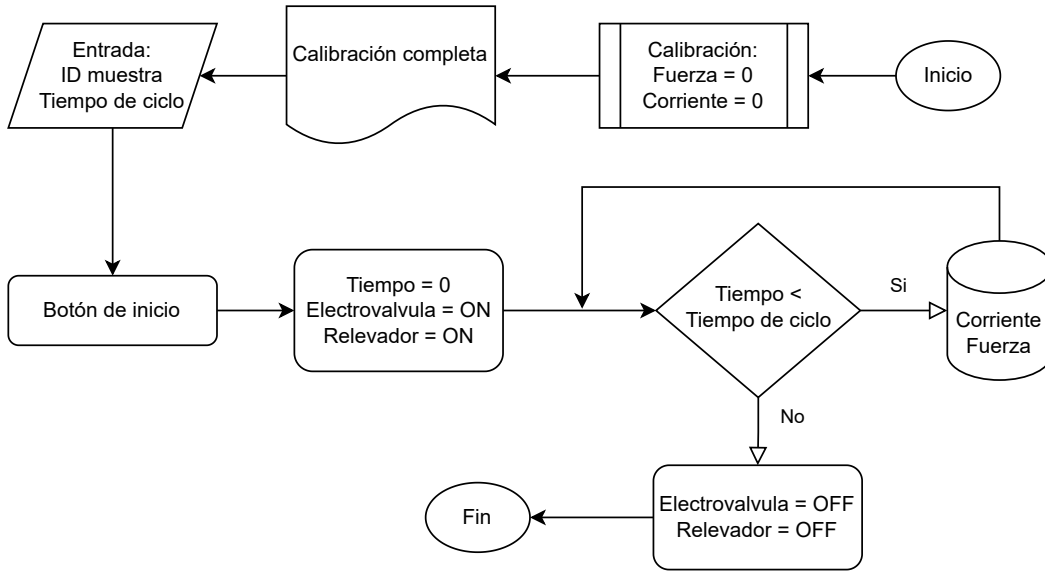


Figura 6.3: Diagrama de flujo del programa.

6.1.1. Registro de Fuerza de los electrodos

En circuito electrónico (Figura 6.4) para registro de fuerza aplicada a los electrodos durante el proceso, se utilizó una celda de carga PSD-S1 de 300kg (especificaciones en la Tabla 6.1) y un convertidor analógico-digital para básculas HX711 de 24 bits.




Figura 6.4: Circuito electrónico para registro de fuerza.

Tabla 6.1: Especificaciones de celda de carga PSD-S1

Característica	Valor
Carga máxima	300 kg
Voltaje de alimentación	5V
Sensitividad	2 milivoltios por volt

El convertidor HX711 permite obtener una sensibilidad en la medición de 0.0178g. Este circuito integrado utiliza un protocolo de comunicación serial, el cual trasmite la información por dos salidas digitales: una para datos (DOUT) y otra para el reloj (SCK). Cuando DOUT se encuentra en un estado bajo, indica que un nuevo dato está listo, después manda los 24 bits y DOUT vuelve a un estado alto. Este circuito cuenta con una librería en la plataforma de Arduino “HX711_ADC.h”, la cual cuenta con una función de calibración que se realiza utilizando un peso conocido para poder ajustar cualquier desviación, este dato es posteriormente guardado en la memoria EEPROM. Esta tarjeta electrónica comercial proporcionaría una sensibilidad mayor, ya que cuenta con un ADC de mayor resolución (24 bits) en comparación con el ADC de 10 bits del Arduino. Además, esta tarjeta viene acompañada de documentación técnica detallada con bibliotecas y funciones específicas para las celdas de carga, lo que facilita su integración. Esta mayor sensibilidad y el soporte hacen de la HX711 una opción superior para proyectos que requieren mediciones precisas. Se realizó un registro de la fuerza con una frecuencia de 10 muestras por segundo (SPS, por sus siglas en inglés).

6.1.2. Registro de Corriente de soldadura

Para la medición de la corriente que pasa a través de los electrodos se diseñó un circuito (Figura 6.5), que consta de un transformador de corriente de TS-816 6000/5A (especificaciones en la Tabla 6.2), el cual genera una corriente de 5 amperes por cada 6000 amperes que pasan por la corriente principal, y un medidor de corriente ACS712. Se realizó un registro de la corriente con una frecuencia de 10 muestras por segundo (SPS, por sus siglas en inglés).




Figura 6.5: Circuito electrónico para registro de corriente.

Tabla 6.2: Especificaciones de transformador de corriente TS-816

Característica	Valor
Corriente primaria medida	6000 A máximo
Corriente secundaria	0 – 5 A
Relación de transformación	6000/5 A
Frecuencia	50-60Hz

Para medir la señal del transformador de corriente se utilizó un medidor de corriente ACS712 para convertir la señal de corriente a voltaje, y así poder registrar la corriente aplicada que fluye a través de las placas metálicas a el Arduino por medio de una entrada analógica, este tiene una sensibilidad de 100 mV por ampere. También cuenta con una librería en Arduino “ACS712.h”, la cual cuenta con las funciones de calibración la cual pone en cero al sensor y medición de corriente AC, y utiliza la raíz cuadrada media (RMS, por sus siglas en inglés) para la medición. Esta tarjeta brinda una medición confiable [50], ya que sus componentes han sido sometidos a rigurosas pruebas y han sido certificados, lo que garantiza su calidad y eficacia. Además, la completa documentación técnica que acompaña a esta tarjeta incluye curvas características detalladas [51].

6.1.3. Regulación de fuerza aplicada a los electrodos

Para modular y regular la cantidad de fuerza aplica a los electrodos, se realizó un circuito electrónico y neumático (Figura 6.6), el cual incluye un cilindro neumático de doble efecto SMC N12D16-300 (especificaciones en la Tabla 6.3). La activación del cilindro se consigue mediante el uso de una electroválvula direccional de 5/2 vías (especificaciones en la Tabla 6.4), activada por una salida digital del Arduino UNO. La fuerza aplicada al sistema es regulada mediante el ajuste de una presión específica por medio de un regulador de presión. Este enfoque proporciona un medio de control preciso del proceso de aplicación de fuerza.

Tabla 6.3: Especificaciones de cilindro neumático

Característica	Valor
Carrera	800 mm
Diámetro del embolo	16 mm
Presión máxima	100 PSI

Tabla 6.4: Especificaciones electroválvula

Característica	Valor
Función de la válvula	Monoestable 5/2 vías
Tipo de accionamiento	Electrónico
Voltaje de alimentación	12V DC
Presión de funcionamiento	35 - 100 PSI




Figura 6.6: Circuito electrónico y neumático para control de fuerza.

6.2. Generación de muestras

6.2.1. Parámetros de muestras

Se construyeron diferentes muestras mediante la combinación de los límites establecidos en un diseño de experimentos de factorial completo (especificaciones Tabla 6.5) con un total 32 muestras generadas de manera aleatoria para evitar el sesgo de los datos. Las muestras malas se obtuvieron mediante una combinación del tiempo de ciclo mínimo y máximo, y el ángulo del electrodo a 15° , mientras que las muestras buenas se generaron con los parámetros centrales del tiempo de ciclo a un ángulo entre electrodos de 0° . Cada muestra fue etiquetada con un número de identificación para mantener la rastreabilidad de los parámetros utilizados para su producción y así formar parte de la información contenida en la base de datos.

Tabla 6.5: Diseño de experimentos, 3 factores a 2 niveles y 4 repeticiones

Parámetro	Descripción	Tipo de dato	Comentario
Tiempo	Tiempo de ciclo (ms)	Continuo	200 - 1500 ms
Presión	Presión en el cilindro neumático	Continuo	35 - 95 PSI
Ángulo	Ángulo entre electrodos ($^\circ$)	Continuo	0 - 15°

La construcción de las piezas restantes se generó a partir de combinaciones de los parámetros de configuración de tiempo de soldado, ángulo entre electrodos y presión de los electrodos. Las muestras se realizaron variando el tiempo de soldadura dentro de un intervalo de [400 - 1200 ms], con incrementos de 200 ms. Para variar el ángulo entre electrodos se utilizaron dos juegos de puntas de electrodos. El primero con un ángulo de 0 grados (superficies de contacto paralelas), mientras que el otro se colocó en un ángulo de 15 grados entre las superficies de contacto entre los electrodos. Se utilizaron dos rangos de presión 60 y 80 PSI para construcción de las muestras debido a que este

parámetro no mostró efecto en el diseño de experimentos con respecto a la prueba de jalón.

6.2.2. Estado de los electrodos

Durante la generación de las muestras se supervisó el estado de los electrodos (especificaciones en la Tabla 6.6) después de cada muestra y, en caso de salpicadura de material en la punta, se utilizó una lima para eliminar el exceso de material restableciendo el diámetro y la superficie plana (Figura 6.7).

Tabla 6.6: Especificaciones de electrodos

Característica	Especificación
Material	Aleación de cobre
Diámetro de contacto	1/8 in




Figura 6.7: Electrodo con salpicaduras de material en la punta (a), y restaurado a su forma original (b).

6.2.3. Captura de imágenes

Las imágenes se tomaron desde una distancia de 15 cm para las imágenes de superficie y aproximadamente a 10 cm para las imágenes termográficas. Las imágenes termográficas se capturaron inmediatamente después de realizar el proceso de soldadura de manera manual, durante la fase de enfriamiento, ya que no es posible realizar una toma durante el proceso debido al reflejo del metal. No obstante, las imágenes muestran el tamaño, la forma y la propagación de la zona afectada por el calor.

6.2.4. Evaluación física de la calidad

Las muestras se construyeron de acuerdo a las especificaciones dimensionales (Figura 6.8) del estándar AWS D8-9 [8], las muestras se solaparon entre si, para para realizar el proceso de soldado.




Figura 6.8: Tamaño y configuración de las muestras de soldadura.

Las pruebas de jalón se realizaron con una máquina universal Tinus Olsen con una capacidad de carga máxima de 300KN y una resolución de 0.1N. Tras realizar la prueba de jalón, se midió el diámetro de la fusión con un vernier electrónico con una resolución de 0.01 mm y se clasificó en muestras buenas, malas y con salpicaduras.

El proceso de la prueba de jalón se llevó a cabo alineando las placas metálicas entre dos mordazas en forma de V (Figura 6.9), estas mordazas tienen un moleteado que evita el desplazamiento de las piezas durante la prueba. Posteriormente se ejerció fuerza hasta alcanzar el punto de quiebre de la pieza. Finalmente se registró el valor más alto obtenido durante la prueba.



Figura 6.9: Preparación de prueba de jalón.

Se clasificaron las muestras en buenas, malas y con salpicaduras (Figura 6.10). La salpicadura es uno de los más comunes del proceso de soldadura por puntos de resistencia, presentando una tendencia en la prueba de jalón [4, 13, 15].




Figura 6.10: Clasificación del punto de soldadura (a) bueno, (b) malo, (c) salpicadura.

Las características de los componentes, incluyendo el tipo de material y el espesor, así como los parámetros de entrada del proceso como la presión del cilindro neumático, el tiempo de ciclo y el ángulo de los electrodos, fueron registrados antes de iniciar el proceso de soldadura por resistencia. Durante el proceso se registraron los parámetros de fuerza de los electrodos y la corriente. Al finalizar el proceso, se obtuvieron imágenes de superficie por ambos lados de la pieza y una imagen termográfica del punto de fusión, además de registrar la fuerza de jalón máximo y el diámetro de fusión.

6.3. Procesamiento de imágenes

Debido a que las regiones de puntos de soldadura solo ocupan una pequeña parte del área total, las imágenes digitales y termográficas fueron procesadas para segmentar la región de la soldadura y redimensionar el tamaño de la imagen. Adicionalmente las imágenes fueron filtradas para remover ruido y características no deseadas para mejorar la calidad de la imagen.

Para el preprocesamiento de las imágenes se ubicó el punto central de la soldadura mediante el software “Geeqie” (Figura 6.11), este proporciona la información de los pixeles de una imagen. Las coordenadas de los puntos de soldadura se registraron de manera manual por cada una de las imágenes y se registraron en un archivo CSV. Posteriormente utilizando la librería de OpenCV, se importaron cada una de las imágenes, después tomando el punto central de la soldadura se recortó el arreglo de la imagen al punto central ± 175 en el eje de las x's y punto central ± 175 en el eje de las y's, cortando las imágenes de superficie a un tamaño de 350x350 pixeles. Las imágenes termográficas se recortaron a 300x300 pixeles. También, se incorporó una escala de 1cm en las imágenes como referencia del tamaño de fusión.



Figura 6.11: Coordenadas de pieza 100_B, utilizando Software Geeqie.

Las imágenes de superficie (Figura 6.12) fueron tomadas de la parte delantera (F) y trasera (B) del punto de soldadura y nombradas según el mismo número de identificación.




Figura 6.12: Ejemplo de imagen de superficie del proceso de soldadura por puntos estandarizada a 350×350 píxeles.

Las imágenes termográficas (Figura 6.13) fueron nombradas según el número de identificación

de la muestra.




Figura 6.13: Ejemplo de imagen termográfica del proceso de soldadura por puntos estandarizada a 300×300 píxeles.

6.4. Generación de base de datos

Se soldaron un total de 495 unidades variando las fuerzas de los electrodos, los ángulos de los electrodos y los tiempos de soldadura. Los parámetros de configuración y los parámetros de monitoreo se guardaron en un archivo CSV (Valores separados por comas, por sus siglas en inglés). La base de datos generada fue publicada en el repositorio de Mendeley [52].

Los atributos de la base de datos se describen en la Tabla 6.7.

Tabla 6.7: Descripción de los atributos del base de datos

N.	Atributo	Formato	Descripción
1	Número de muestra	Numérico	Número de identificación único para cada muestra
2	Presión	Numérico	Presión en el cilindro neumático
3	Tiempo de soldadura	Numérico	Tiempo del proceso de soldadura
4	Ángulo de electrodos	Numérico	Ángulo entre los electrodos
5	Fuerza de electrodos	Numérico	Fuerza aplicada a los electrodos
6	Corriente de soldadura	Numérico	Corriente que circula por los componentes
7	Espesor del material	Numérico	Espesor del material
8	Tipo de material	Categorico	Composición del material
9	Fuerza de jalón	Numérico	Resistencia mecánica de la unión soldada
10	Diámetro de fusión	Numérico	Diámetro de la fusión de la soldadura
11	Clasificación	Categorico	Categoría del punto de soldadura (bueno, malo, salpicadura)

En los atributos de configuración, se registró el valor inicial de la presión que alimenta el circuito neumático (atributo 2), el valor asignado de tiempo de soldado (atributo 3), y el ángulo entre las superficies de contacto entre los electrodos (atributo 4).

Para los atributos de fuerza de los electrodos (atributo 5) y corriente de soldadura (atributo 6), se generó un registro de las mediciones durante el tiempo de soldado, con una frecuencia de 10 muestras por segundo. Sin embargo, debido a la diversidad de tiempos de soldado entre piezas, cada muestras tiene una longitud diferente en el registro de estos parámetros. Por lo que fue necesario

utilizar medidas de dispersión de los datos como valor mínimo, máximo y promedio del registro de las mediciones de cada pieza para ser utilizados en la red neuronal convolucional.

Adicionalmente se realizó una correlación de Pearson para determinar cuáles de estos parámetros de entrada tienen una mayor relación con los parámetros de la calidad y así ser utilizados como entrada de las redes neuronales convolucionales.

Los atributos que describen las características del material son el espesor del material (atributo 7), en el cual se registró el espesor de ambas placas metálicas con el uso de un micrómetro, y el tipo de material (atributo 8) en donde solo se utilizó acero al carbón calidad AISI 1010.

En los atributos relacionados a la calidad de la soldadura, se encuentra el registro del diámetro de fusión (atributo 9) registrado tras realizar la prueba de jalón con el uso de un vernier electrónico, y el valor de fuerza máximo obtenido durante la prueba de jalón (atributo 10).

El atributo visual de la clasificación de la calidad (atributo 11) está definido por tres clases: buenas, malas y con salpicadura.

Adicionalmente se revisó la dispersión de los datos (Tabla 6.8) y el balance de las clases (Tabla 6.9).

Tabla 6.8: Rango de valores

Atributo	Mínimo	Máximo
Presión	35	95
Tiempo de soldado	200	1500
Ángulo de electrodos	0	15
Fuerza de electrodos	0	133.53
Corriente de soldadura	639.81	5009.43
Espesor del material (A)	0.61	1.057
Espesor del material (B)	0.608	1.01
Fuerza de jalón	1410.3	5806.5
Diámetro de fusión	1.9	4.72

Tabla 6.9: Balance de clases

Clase	Categoría	Cantidad	Porcentaje
0	Mala	31	6 %
1	Buena	443	89 %
2	Salpicadura	21	4 %

6.5. Desarrollo de red neuronal convolucional

6.5.1. Selección de modelo

Se evaluaron diferentes arquitecturas de redes neuronales convolucionales del estado del arte, para extraer características en las imágenes termográficas y de superficie. Estas fueron entrenadas con la base de datos generada.

Se realizaron un total de seis modelos para la evaluación de la calidad del proceso de soldadura por resistencia y sus parámetros de entrada. En estos modelos se utilizaron cuatro arquitecturas

seleccionadas del estado del arte para determinar si existe una diferencia significativa en el desempeño y encontrar el mejor modelo. Tres de estos modelos están basados en imágenes de superficie, mientras que los otros tres utilizan imágenes termográficas.

El resumen de estos modelos se describe a continuación.

1. Calidad por imágenes de superficie: Es un modelo clasificador de calidad en base a imágenes de superficie. Las categorías de salida son “buena”, “mala” y “salpicadura”.
2. Calidad por imágenes termográficas: Es un modelo clasificador de calidad en base a imágenes termográficas. Las categorías de salida son “buena”, “mala” y “salpicadura”.
3. Predicción de calidad por imágenes de superficie: Es un modelo que predice los parámetros de calidad de diámetro de fusión y fuerza de jalón, en base a imágenes de la superficie del punto de fusión.
4. Predicción de la calidad por imágenes termográficas: Es un modelo que predice los parámetros de calidad de diámetro de fusión y fuerza de jalón, en base a imágenes termográficas del punto de fusión.
5. Predicción de parámetros de entrada por imágenes de superficie: Es un modelo que predice los parámetros de entrada de presión del cilindro neumático, ángulo de electrodos, espesor del material, tiempo de soldado, fuerza de los electrodos (mínima y máxima), y corriente de soldadura máxima, en base a imágenes de superficie.
6. Predicción de parámetros de entrada por imágenes termográficas: Es un modelo que predice los parámetros de entrada de presión del cilindro neumático, ángulo de electrodos, espesor del material, tiempo de soldado, fuerza de los electrodos (mínima y máxima), y corriente de soldadura máxima, en base a imágenes termográficas.

Se probaron diferentes arquitecturas del estado del arte, entre las cuales se seleccionó el modelo LeNet-5 por su simplicidad, lo que la hace un buen punto de partida para experimentar y ser comparadas con arquitecturas más complejas, adicionalmente tiene un bajo costo computacional. Los modelos MobileNet, ResNet50 y DenseNet201 son utilizadas dentro del estado del arte [4] para la evaluación y comparación, dentro de estos se seleccionaron las arquitecturas de MobileNet y ResNet50 por su menor tiempo de inferencia dentro de su familia, mientras que el modelo DenseNet201 presenta la mayor profundidad dentro de su familia con 402 capas.

La arquitectura del modelo LeNet-5 se adaptó para un arreglo de entrada de 350x350 en el caso de las imágenes de superficie y una salida con tres neuronas para las diferentes clases (Figura 6.14).

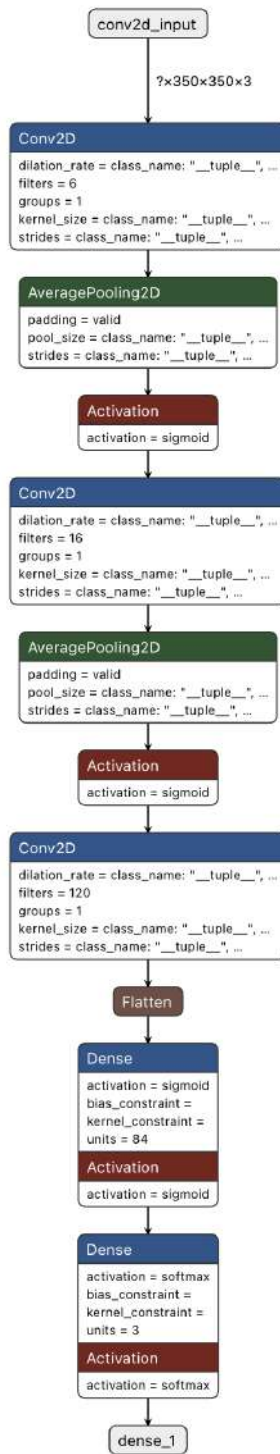


Figura 6.14: Arquitectura red LeNet-5.

Para los demás modelos se importaron las arquitecturas sin cabecera y se agregó una para procesar la información (Figura 6.15), se agregaron las capas “Flatten” para aplanar los datos, una capa densa con activación sigmoide de 84 neuronas y finalmente una capa densa con activación softmax con 3 neuronas de salida.




Figura 6.15: Cabecera de modelos MobileNet, ResNet50 y DenseNet201.

Todos los modelos se entrenaron de manera inicial con los hiperparámetros de la Tabla 6.10.

Tabla 6.10: Hiperparámetros de entrenamiento

Hiperparámetro	Valor
Optimizador	Adam
Tasa de aprendizaje	0.001
Función de pérdida (modelos clasificación)	Categorical crossentropy
Función de pérdida (modelos predicción)	mean squared error
Tamaño de lote	32
Épocas	50

6.5.2. Entrenamiento de modelo

Para el entrenamiento del algoritmo se requiere de un conjunto de datos etiquetados, por lo que es necesario tener un valor cuantificable asociado a cada muestra, para tener una correlación entre entrada (parámetros, imágenes termográficas y de superficie) y salida (fuerza mecánica, diámetro de fusión y defectos visuales).

Se generó un arreglo para almacenar las imágenes de entrada de los 6 modelos y ser utilizado como entrada de los diferentes modelos (Figura 6.16 imágenes de superficie y Figura 6.17 imágenes termográficas).

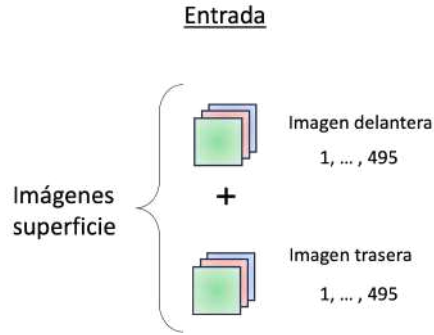


Figura 6.16: Arreglos de entrada para modelos en base a imágenes de superficie.

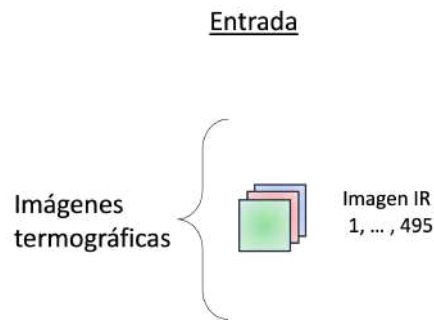


Figura 6.17: Arreglos de entrada para modelos en base a imágenes termográficas.

En los modelos 1 y 2, se generó un arreglo con las etiquetas de salida en formato “OneHot” [1. 0. 0.] mala, [0. 1. 0.] buena, [0. 0. 1.] salpicadura. En los modelos 3 y 4, se generó un arreglo con los valores de los parámetros de calidad de fuerza de jalón y diámetro de fusión. Por último, se generó un arreglo de salida para los modelos 5 y 6, el cual contiene los parámetros de entrada presión del cilindro neumático, ángulo de electrodos, espesor del material, tiempo de soldado, fuerza de los electrodos (mínima y máxima), y corriente de soldadura máxima.

Estos arreglos se dividieron de manera aleatoria en grupos de entrenamiento (60%), validación (20%) y prueba (20%) de acuerdo con la regla 60-20-20. Por último, se normalizaron los datos de entrada de acuerdo al procesamiento de cada modelo.

Los resultados del entrenamiento de cada modelo se compararon entre las arquitecturas seleccionadas dentro del estado del arte para seleccionar el mejor modelo. Para la evaluación de los modelos 1 y 2 se utilizó la métrica de la precisión, por tratarse de modelos de clasificación. Para el resto de los modelos se utilizó la métrica del error medio absoluto (MAE), ya que se trata de una predicción.

6.5.3. Búsqueda de hiperparámetros

Una vez seleccionada la mejor arquitectura para cada uno de los modelos, se realizó una búsqueda para la optimización de hiperparámetros usando Keras Tuner, el cual cuenta con algoritmos de optimización bayesiana, de hiperbanda y búsqueda aleatoria [53]. Para el presente trabajo se realizó

una búsqueda aleatoria en el espacio de búsqueda descrito en la Tabla 6.11.

Tabla 6.11: Espacio de búsqueda Keras Tuner

Hiperparámetro	Valor
Tasa de aprendizaje	1e-05 - 0.01
Función de activación	relu, sigmoid
Número de neuronas	32 - 512
Número de pruebas	10
Objetivo (modelos clasificación)	Exactitud de validación
Objetivo (modelos predicción)	MAE de validación

6.5.4. Análisis de resultados

La efectividad de cada modelo se verifico por medio de la estrategia de validación cruzada utilizando grupos de $k = 4, 5$ y 9 . En base a los resultados obtenidos en la evaluación de pruebas contra los valores estimados por la red se comprueba la efectividad y la repetibilidad de los modelos.

6.6. Especificaciones computadora y librerías

El presente proyecto se desarrolló en una macbook pro 2021, con una memoria RAM de 32 GB, y un chip Apple M1 Max con CPU de 10 núcleos, GPU de 24 núcleos y motor neuronal de 16 núcleos.

La programación de los modelos se desarrolló en el lenguaje de programación Python versión 3.9.13, con las siguientes librerías.

- Keras versión 2.10.0
- Tensorflow versión 2.10.0
- Numpy versión 1.23.2
- Pandas versión 1.5.1
- Matplotlib versión 3.7.3
- Seaborn versión 0.12.2
- Opencv versión 4.6.0.66

Resultados y discusión

7.1. Integración de banco de pruebas

Es necesario garantizar la precisión y fiabilidad en la medición, por lo cual se realizó una calibración de los parámetros de fuerza aplicada a los electrodos y corriente, así como también múltiples pruebas con diferentes rangos para determinar repetibilidad de la medición.

La calibración del sensor de corriente se llevó a cabo por medio de la función “calibrate()” de la librería “ACS712.h”, esta realiza una compensación de los valores iniciales del sensor. La calibración de la fuerza de los electrodos se realizó por medio de la función “setCalFactor” de la librería “HX711_ADC.h”, donde se le asignó un valor de -14.59. Este valor fue definido mediante una rutina de calibración utilizando la función “calibrate()” de la librería “HX711_ADC.h”, calculando el factor de escala por medio de la medición de una masa conocida contra la lectura del sensor. Adicionalmente se define un tiempo de estabilización de 2000ms. Al terminar la calibración de los sensores imprime un mensaje de “Calibración completa”.

Para la celda de carga se utilizaron múltiples masas constantes de 266 g, previamente pesadas con una báscula calibrada, cambiando el número de masas para incrementar el peso en un rango de 0 g a 2128 g, tomando 31 puntos de medición por cada paso. Los resultados fueron consistentes, demostrando la precisión de la celda de carga para una amplia gama de mediciones de peso. Con este nivel de confianza, se puede fiar del banco de pruebas para la medición de la fuerza aplicada. Los resultados entre la fuerza real y la medición del banco de pruebas se muestran en la Tabla 7.1.

Tabla 7.1: Resultados de fuerza real contra mediciones

Dato Real	0g	266g	510g	765g	1020g	1275g	1530g	1785g	2040g
Media de medición	0.18g	264.42g	529.26g	797.45g	1064.5g	1332.9g	1599.8g	1866.2g	2132.5g
Desviación estándar	0.271	7.022	3.618	0.331	0.245	0.232	0.950	0.667	0.330

En la medición de corriente se aplicaron múltiples tensiones con el uso de un regulador de voltaje de corriente alterna y una resistencia constante para generar diferentes rangos de corriente verificados con el uso de un multímetro Fluke 177, el cual tiene una resolución de 0.01 mA y puede medir una corriente máxima de 10 A. Se hicieron pruebas dentro de un rango de corriente de 0 A a 5 A, con incrementos de 0.5 A, tomando un total de 35 puntos de datos en cada paso. Se encontró que los resultados fueron consistentes y repetibles, debido a que los valores medidos se ajustan a

los valores reales esperados, demostrando la precisión del circuito y sus mediciones. Los resultados entre la corriente real y la medición del banco de pruebas se muestran en la Tabla 7.2.

Tabla 7.2: Resultados de corriente real contra mediciones

Dato Real	0A	0.5A	1A	1.5A	2A	2.5A	3A	3.5A	4A	4.5A	5A
Media de medición	0A	0.50A	0.99A	1.47A	1.93A	2.46A	2.86A	3.31A	3.82A	4.44A	4.84A
Desviación estándar	0	0.025	0.042	0.069	0.093	0.111	0.15	0.153	0.179	0.205	0.226

Por último, se midió la fuerza de aplicada a los ajustando la presión de alimentación en diferentes rangos, para determinar la relación entre el suministro de presión y la fuerza medida. El proceso consistió en activar manualmente la electroválvula y registrar 121 puntos de datos por muestra. El rango de presiones aplicadas se realizó con una presión mínima de 35 PSI (necesaria para la activación de la válvula) hasta un máximo de 95 PSI (presión máxima soportada por el cilindro neumático). Para garantizar la repetibilidad, se registraron 30 muestras en cada paso. Los resultados de este experimento determinó la variación de las mediciones a distintos niveles de presión.

Las gráficas con los registros de fuerza en el rango de 35 PSI – 95 PSI, con incrementos de 15 PSI entre pruebas (Figura 7.1). Cada gráfica contiene 30 muestras de una activación manual. Se observa que el punto máximo tiene poca variabilidad entre las 30 muestras, indicando que el proceso es constante y repetible.

A diferencia de los trabajos anteriores que proponen el uso de una bobina Rogowski como sensor de corriente, este trabajo propone la integración de un transformador de corriente, así como también el registro de la fuerza aplicada al sistema durante el proceso para medir la variación de estos parámetros durante el proceso de RSW. Adicionalmente, la variabilidad de las mediciones y la caracterización precisa de la fuerza en el proceso de soldadura por resistencia también están incluidas en esta investigación.

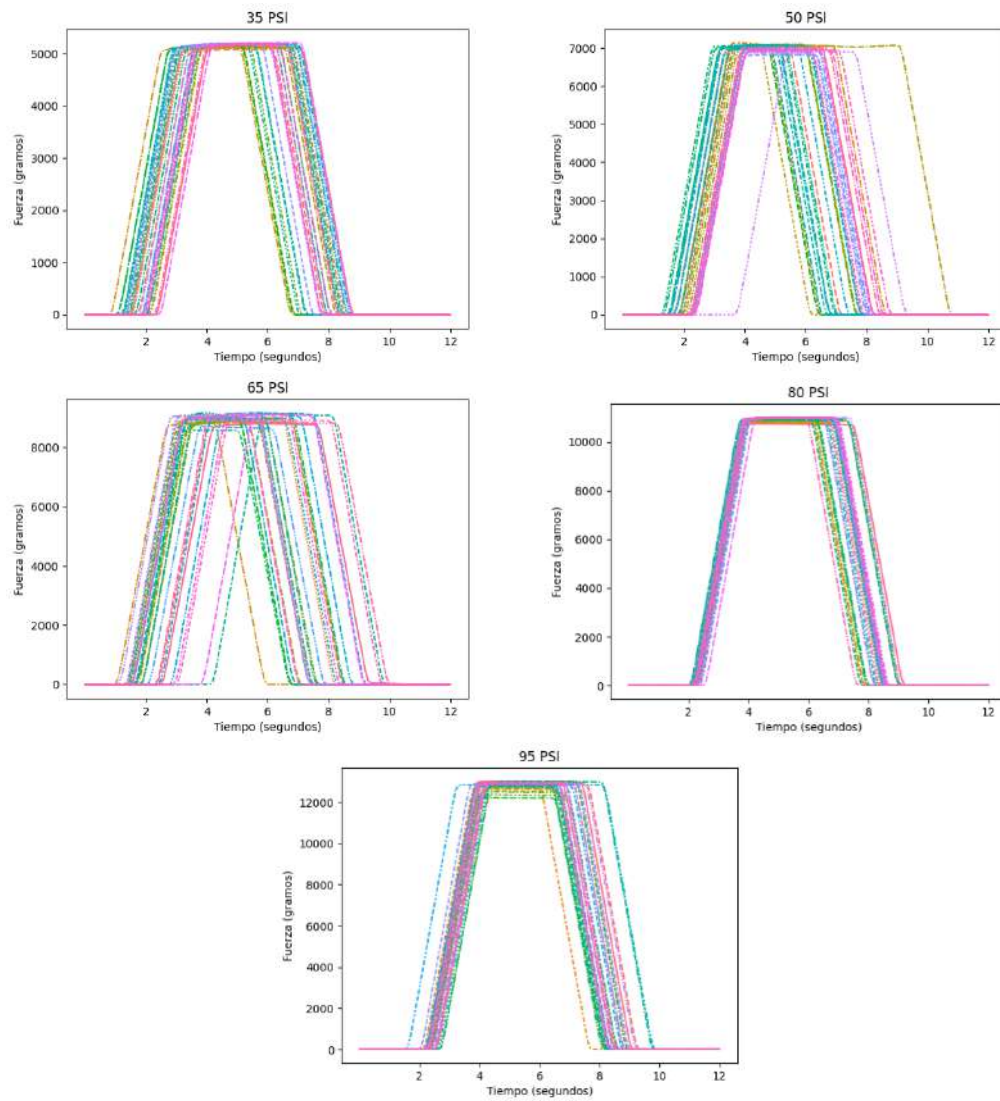


Figura 7.1: Registro fuerza de 30 muestras con activación manual a 35 PSI - 95 PSI.

7.2. Correlación de parámetros

Para evaluar el efecto de los parámetros de entrada del proceso de RSW (tiempo de soldadura, ángulo entre electrodos, y presión en el cilindro neumático), se desarrolló un diseño de experimentos factorial completo con 4 repeticiones de cada combinación para un total de 32 muestras. Se evaluó su efecto contra la resistencia mecánica (Figura 7.2), indicando que el factor de tiempo de soldado es el más significativo, seguido del ángulo entre electrodos, y finalmente la presión del cilindro neumático, la cual no presentó ningún efecto ante la fuerza de jalón.

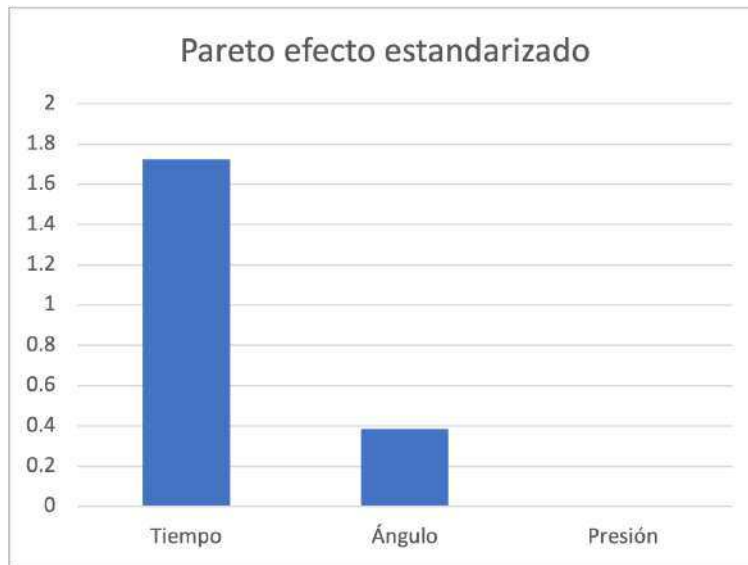


Figura 7.2: Pareto de efecto de parámetros de entrada en diseño de experimentos.

Para determinar la relación de los parámetros de entrada con respecto a los parámetros de calidad se realizó una matriz de correlación de Pearson (Figura 7.3). Los parámetros de corriente de soldadura y fuerza de los electrodos se utilizaron las medidas de dispersión de los datos de valor mínimo, máximo y promedio de las series de tiempo.

Como se puede apreciar en la matriz de correlación de Pearson, el parámetro de tiempo de soldado es el que tiene una mayor correlación con los parámetros de calidad de fuerza de jalón y diámetro de fusión de 0.55598 y 0.472734. Las descripciones de las series de fuerza de los electrodos, se encuentra que la fuerza mínima y máxima son las que tienen una mayor correlación con respecto a los parámetros de calidad de -0.28668 y 0.114633. Por otro lado, en la serie de tiempo de corriente de soldadura, se encuentra la descripción de corriente máxima como el parámetro con mayor correlación de -0.164266 y 0.219147.




Figura 7.3: Matriz de correlación Pearson.

7.3. Modelos CNN

7.3.1. Modelo 1 - Clasificador de calidad por categorías: buena, mala y salpicadura, en base a imágenes de superficie

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 1 se encuentran resumidos en la Tabla 7.3. Las gráficas de exactitud y pérdida de los diferentes modelos se muestran en las Figuras 7.4-7.7.

Tabla 7.3: Resultados arquitecturas modelo 1

Modelo	Exactitud entrenamiento	Exactitud validación	Exactitud Prueba	Tiempo de predicción (s)
LeNet-5	89.06 %	89.90 %	90.40 %	0.038
MobileNet	89.06 %	89.90 %	90.40 %	0.053
ResNet50	89.06 %	89.90 %	90.40 %	0.167
DenseNet201	89.06 %	89.90 %	90.40 %	0.538




Figura 7.4: Exactitud y pérdida en entrenamiento y validación de red LeNet-5 de modelo 1.




Figura 7.5: Exactitud y perdida en entrenamiento y validación de red MobileNet de modelo 1.




Figura 7.6: Exactitud y perdida en entrenamiento y validación de red ResNet50 de modelo 1.




Figura 7.7: Exactitud y perdida en entrenamiento y validación de red DenseNet201 de modelo 1.

Como se puede observar, no existe una diferencia entre el desempeño de la red más ligera (LeNet-5) y las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.4) con dos repeticiones en el espacio de búsqueda descrito en la Tabla 6.11, buscando la optimización de la métrica de exactitud en la validación.

Tabla 7.4: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 1

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	Exactitud validación	Exactitud Prueba
6	1.41E-05	relu	32	93.18 %	94.44 %
5	4.60E-04	sigmoid	320	89.90 %	93.94 %
4	1.96E-05	relu	16	93.43 %	93.43 %
1	9.10E-05	relu	320	92.68 %	93.43 %
2	1.60E-03	relu	64	92.42 %	93.43 %
3	9.51E-03	relu	128	89.90 %	93.43 %
10	4.77E-05	relu	416	93.43 %	90.40 %
7	1.74E-05	relu	96	93.43 %	90.40 %
9	6.68E-05	sigmoid	288	89.90 %	90.40 %
8	1.15E-04	sigmoid	448	89.90 %	90.40 %

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 6. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de Exactitud, Precisión, Recall y F1 score (resultados Figura 7.8).




Figura 7.8: Validación cruzada modelo 1, prueba 6.

7.3.2. Modelo 2 - Clasificador de calidad por categorías: buena, mala y salpicadura, en base a imágenes termográficas

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 2 se encuentran resumidos en la Tabla 7.5. Las gráficas de exactitud y pérdida de los diferentes modelos se muestran en las Figuras 7.9-7.12.

Tabla 7.5: Resultados arquitecturas modelo 2

Modelo	Exactitud entrenamiento	Exactitud validación	Exactitud Prueba	Tiempo de predicción (s)
LeNet-5	88.89 %	91.92 %	88.89 %	0.048
MobileNet	88.89 %	91.92 %	88.89 %	0.036
ResNet50	88.89 %	91.92 %	88.89 %	0.108
DenseNet201	88.89 %	91.92 %	88.89 %	0.337




Figura 7.9: Exactitud y perdida en entrenamiento y validación de red LeNet-5 de modelo 2.




Figura 7.10: Exactitud y perdida en entrenamiento y validación de red MobileNet de modelo 2.




Figura 7.11: Exactitud y perdida en entrenamiento y validación de red ResNet50 de modelo 2.




Figura 7.12: Exactitud y perdida en entrenamiento y validación de red DenseNet201 de modelo 2.

Como se puede observar, no existe una diferencia entre el desempeño de la red más ligera (LeNet-5) y las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.6) con dos repeticiones en el espacio de búsqueda descrito en la Tabla 6.11, buscando la optimización de la métrica de exactitud en la validación.

Tabla 7.6: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 2

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	Exactitud validación	Exactitud Prueba
3	1.28E-03	relu	320	97.98 %	90.91 %
6	7.45E-04	relu	160	97.47 %	88.89 %
10	3.76E-05	relu	448	96.97 %	88.89 %
4	1.37E-04	sigmoid	96	91.92 %	88.89 %
5	2.67E-04	sigmoid	32	91.92 %	88.89 %
7	3.69E-04	sigmoid	448	91.92 %	88.89 %
8	2.29E-04	sigmoid	384	91.92 %	88.89 %
9	7.48E-04	sigmoid	256	91.92 %	88.89 %
2	3.11E-03	sigmoid	480	91.92 %	8.08 %
1	7.25E-04	sigmoid	320	91.92 %	3.03 %

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 3. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de Exactitud, Precisión, Recall y F1 score (resultados en Figura 7.13).

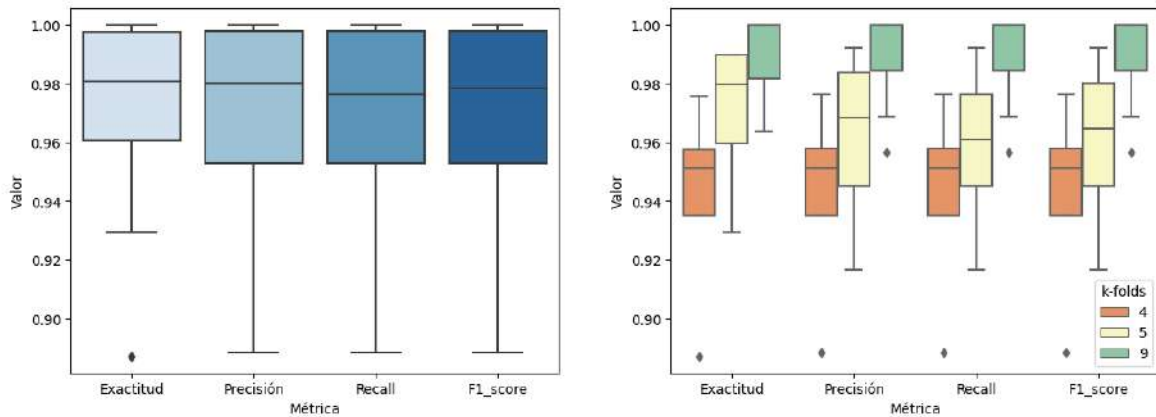


Figura 7.13: Validación cruzada modelo 2, prueba 3.

7.3.3. Modelo 3 - Predicción de parámetros de calidad: diámetro de fusión y fuerza de jalón, en base a imágenes de superficie

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 3 se encuentran resumidos en la Tabla 7.7. Las gráficas de error y perdida de los diferentes modelos se muestran en las Figuras 7.14-7.17.

Tabla 7.7: Resultados arquitecturas modelo 3

Modelo	MAE entrenamiento	MAE validación	MAE Prueba	Tiempo de predicción (s)
LeNet-5	0.0541	0.0480	0.0519	0.038
MobileNet	0.5287	0.5121	0.5264	0.052
ResNet50	0.6186	0.6035	0.6177	0.165
DenseNet201	0.0540	0.0483	0.0519	0.521

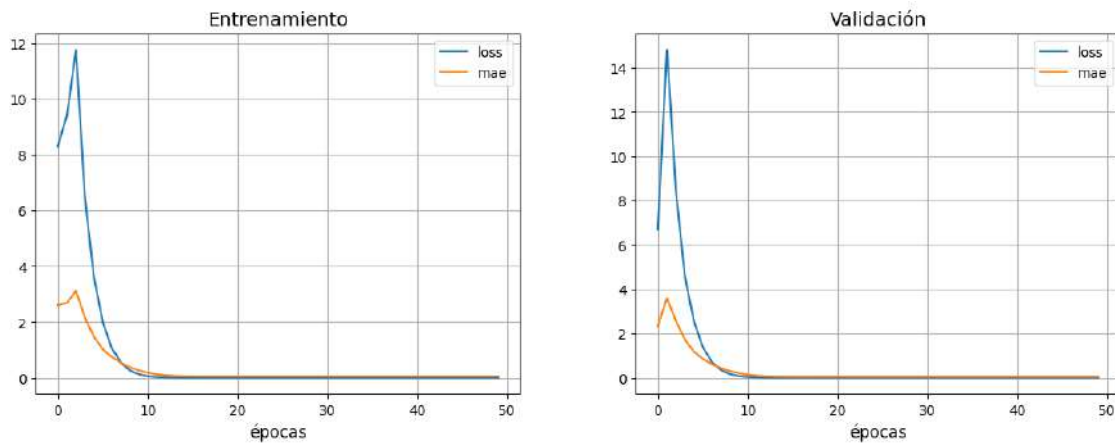


Figura 7.14: MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 3.




Figura 7.15: MAE y perdida en entrenamiento y validación de red MobileNet de modelo 3.




Figura 7.16: MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 3.

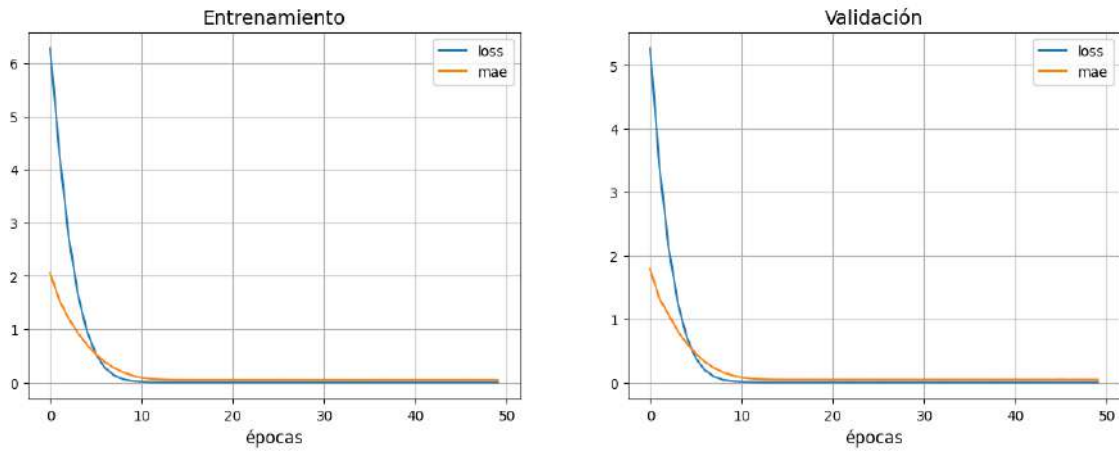


Figura 7.17: MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 3.

Como se puede observar, la red más ligera (LeNet-5) tiene un mejor desempeño en comparación a las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.8) con dos repeticiones en el espacio de búsqueda descrito en la Tabla 6.11, buscando la optimización de la métrica de MAE en la validación.

Tabla 7.8: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 3

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	MAE validación	MAE Prueba
2	1.27E-04	relu	352	0.0373	0.0443
10	4.43E-05	relu	384	0.0373	0.0456
6	2.86E-05	relu	256	0.0366	0.0532
3	3.59E-03	sigmoid	512	0.0461	0.0447
9	1.31E-03	relu	160	0.0416	0.0531
7	4.34E-03	relu	256	0.0459	0.0523
1	1.60E-03	relu	288	0.0561	0.0438
4	3.66E-04	sigmoid	96	0.0555	0.0451
5	2.01E-03	relu	192	0.0567	0.0543
8	6.51E-04	relu	512	0.0762	0.0514

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 2. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de MSE, RMSE, MAE, RAE, RSE, CC y R^2 (resultados en Figura 7.18).




Figura 7.18: Validación cruzada modelo 3, prueba 2.

7.3.4. Modelo 4 - Predicción de parámetros de calidad: diámetro de fusión y fuerza de jalón, en base a imágenes termográficas

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 4 se encuentran resumidos en la Tabla 7.9. Las gráficas de error y perdida de los diferentes modelos se muestran en las Figuras 7.19-7.22.

Tabla 7.9: Resultados arquitecturas modelo 4

Modelo	MAE entrenamiento	MAE validación	MAE Prueba	Tiempo de predicción (s)
LeNet-5	0.0520	0.0494	0.0500	0.026
MobileNet	0.5463	0.5311	0.5377	0.034
ResNet50	0.6244	1.3882	0.8595	0.107
DenseNet201	0.0540	0.0491	0.0509	0.337

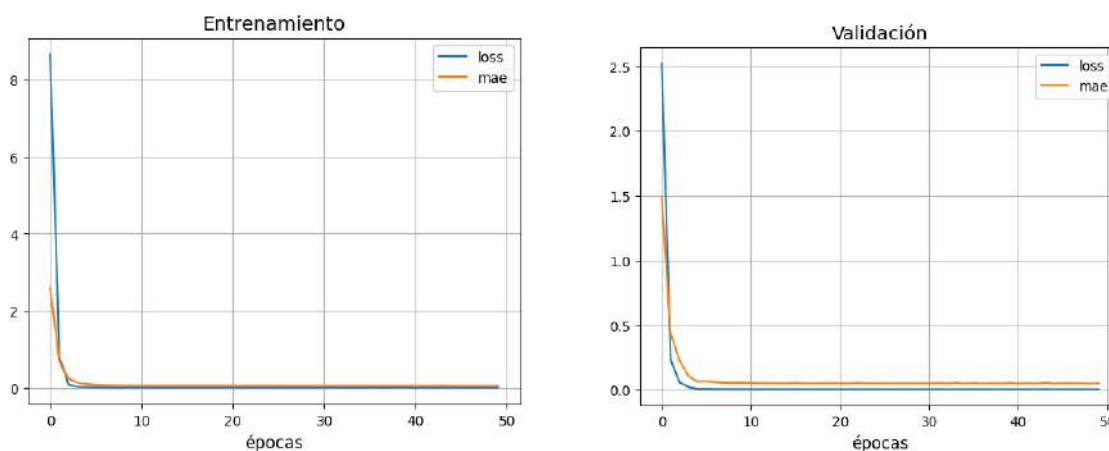


Figura 7.19: MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 4.




Figura 7.20: MAE y perdida en entrenamiento y validación de red MobileNet de modelo 4.




Figura 7.21: MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 4.

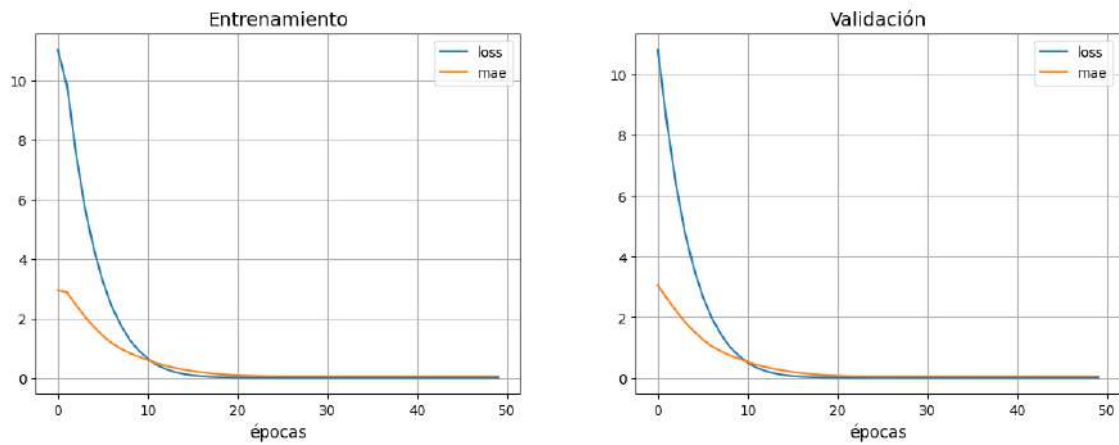


Figura 7.22: MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 4.

Como se puede observar, la red más ligera (LeNet-5) tiene un mejor desempeño en comparación a las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.10) con dos repeticiones en el espacio de búsqueda descrito en la Tabla 6.11, buscando la optimización de la métrica de MAE en la validación.

Tabla 7.10: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 4

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	MAE validación	MAE Prueba
4	5.40E-05	relu	128	0.04328	0.04316
3	9.51E-05	relu	352	0.04513	0.04424
2	4.08E-05	sigmoid	128	0.04733	0.04499
6	2.63E-05	relu	160	0.04581	0.05012
7	1.75E-05	sigmoid	416	0.04772	0.05153
5	9.59E-03	relu	448	0.04912	0.05114
9	1.96E-04	relu	128	0.04444	0.31979
1	2.36E-04	sigmoid	416	0.44517	0.04232
8	1.36E-04	sigmoid	480	1.85237	0.05035
10	2.11E-03	relu	32	0.31017	1.65696

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 4. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de MSE, RMSE, MAE, RAE, RSE, CC y R^2 (resultados en Figura 7.23).




Figura 7.23: Validación cruzada modelo 4, prueba 4.

7.3.5. Modelo 5 - Predicción de parámetros de entrada, en base a imágenes de superficie

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 5 se encuentran resumidos en la Tabla 7.11. Las gráficas de error y perdida de los diferentes modelos se muestran en las Figuras 7.24-7.27.

Tabla 7.11: Resultados arquitecturas modelo 5

Modelo	MAE entrenamiento	MAE validación	MAE Prueba	Tiempo de predicción (s)
LeNet-5	0.1614	0.1651	0.1612	0.039
MobileNet	0.4206	0.4155	0.4199	0.053
ResNet50	0.6051	0.5983	0.6167	0.177
DenseNet201	0.1687	0.1689	0.1707	0.549

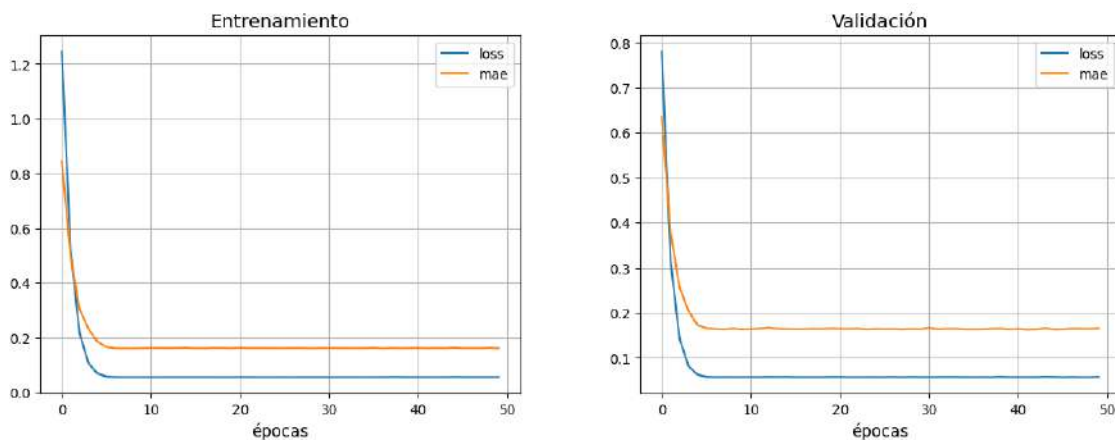


Figura 7.24: MAE y perdida en entrenamiento y validación de red LeNet-5 de modelo 5.




Figura 7.25: MAE y perdida en entrenamiento y validación de red MobileNet de modelo 5.

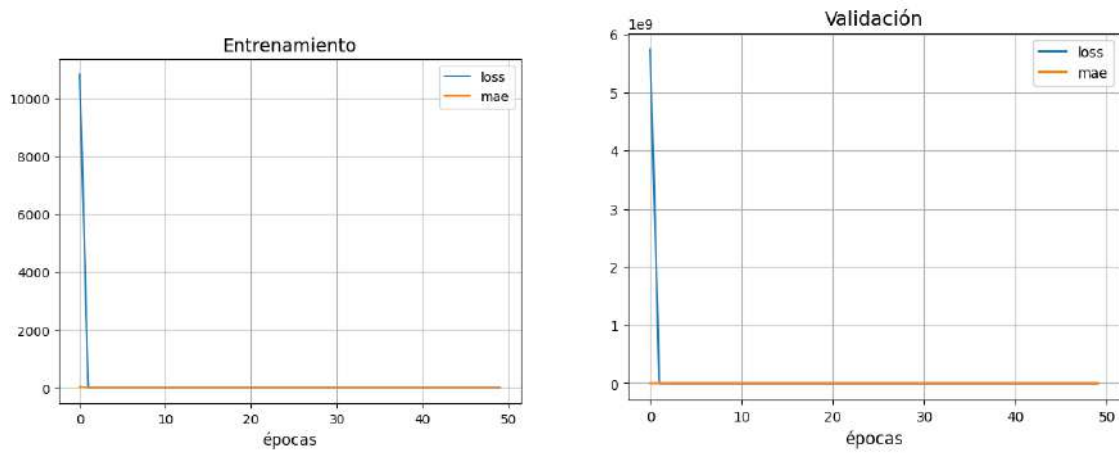


Figura 7.26: MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 5.




Figura 7.27: MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 5.

Como se puede observar, la red más ligera (LeNet-5) tiene un mejor desempeño en comparación a las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.12) con dos repeticiones en el espacio de búsqueda descrito en la Tabla 6.11, buscando la optimización de la métrica de MAE en la validación.

Tabla 7.12: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 5

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	MAE validación	MAE Prueba
3	1.46E-05	relu	288	0.0818	0.0746
2	2.67E-05	relu	64	0.0832	0.0792
6	7.41E-04	relu	192	0.0873	0.0844
9	5.04E-03	relu	128	0.1684	0.1578
1	2.80E-03	relu	512	0.1645	0.1643
7	2.80E-03	relu	160	0.1682	0.1662
4	1.16E-03	relu	64	0.2273	0.1103
5	9.83E-03	relu	64	0.1829	0.1555
8	1.86E-04	sigmoid	128	0.1883	0.1609
10	1.90E-04	relu	64	0.3611	0.1442

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 3. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de MSE, RMSE, MAE, RAE, RSE, CC y R^2 (resultados en Figura 7.28).




Figura 7.28: Validación cruzada modelo 5, prueba 3.

7.3.6. Modelo 6 - Predicción de parámetros de entrada, en base a imágenes termográficas

Los resultados de las pruebas de las diferentes arquitecturas del estado del arte correspondientes al modelo 6 se encuentran resumidos en la Tabla 7.13. Las gráficas de error y pérdida de los diferentes modelos se muestran en las Figuras 7.29-7.32.

Tabla 7.13: Resultados arquitecturas modelo 6

Modelo	MAE entrenamiento	MAE validación	MAE Prueba	Tiempo de predicción (s)
LeNet-5	0.1615	0.1687	0.1535	0.024
MobileNet	0.5025	0.4972	0.5010	0.034
ResNet50	0.6187	0.6131	0.6206	0.107
DenseNet201	0.1624	0.1680	0.1537	0.330

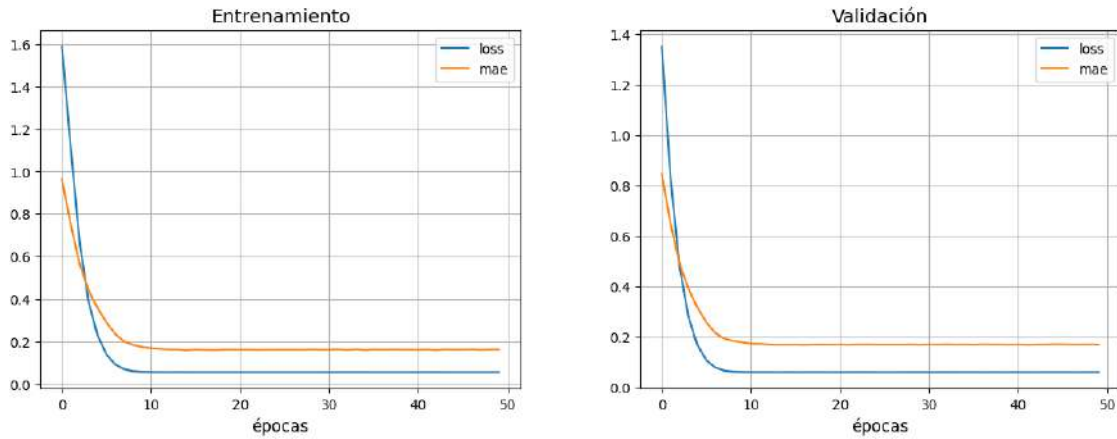


Figura 7.29: MAE y pérdida en entrenamiento y validación de red LeNet-5 de modelo 6.




Figura 7.30: MAE y perdida en entrenamiento y validación de red MobileNet de modelo 6.




Figura 7.31: MAE y perdida en entrenamiento y validación de red ResNet50 de modelo 6.

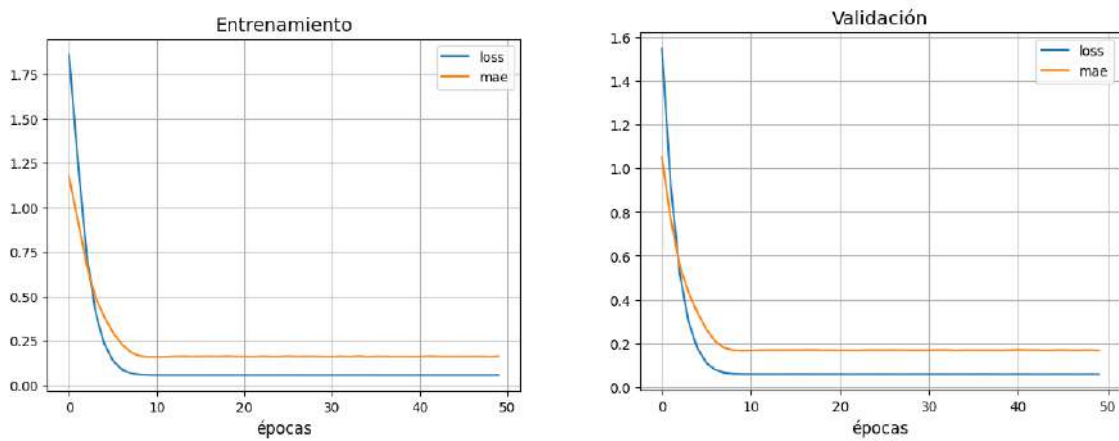


Figura 7.32: MAE y perdida en entrenamiento y validación de red DenseNet201 de modelo 6.

Como se puede observar, la red más ligera (LeNet-5) tiene un mejor desempeño en comparación a las demás, por lo que esta se utilizó como base para la exploración de hiperparámetros por Keras Tuner para su optimización. Se realizó búsqueda aleatoria de diez modelos (Tabla 7.14) con dos repeticiones en el espacio de búsqueda descrito en la tabla 6.11, buscando la optimización de la métrica de MAE en la validación.

Tabla 7.14: Resultados búsqueda de hiperparámetros arquitectura LeNet-5 de modelo 6

Prueba	Tasa de aprendizaje	Función de activación	Número de neuronas	MAE validación	MAE Prueba
10	6.99E-04	relu	64	0.11793	0.10248
4	1.03E-04	relu	192	0.14070	0.08269
5	9.95E-05	relu	192	0.14582	0.09591
2	1.97E-03	relu	288	0.14115	0.12079
1	2.15E-05	sigmoid	224	0.16700	0.15252
8	4.95E-03	sigmoid	480	0.16501	0.15548
9	2.61E-04	sigmoid	352	0.16967	0.15395
3	2.50E-04	sigmoid	448	0.17184	0.15405
7	2.17E-04	sigmoid	64	0.31128	0.28030
6	1.35E-04	sigmoid	416	0.42502	0.39592

Una vez identificado el mejor modelo dentro de la búsqueda, en este caso fue la prueba 10. Se realizó una validación cruzada utilizando grupos de $K = 4, 5$ y 9 . Adicionalmente se utilizaron las métricas de evaluación de MSE, RMSE, MAE, RAE, RSE, CC y R^2 (resultados en Figura 7.33).

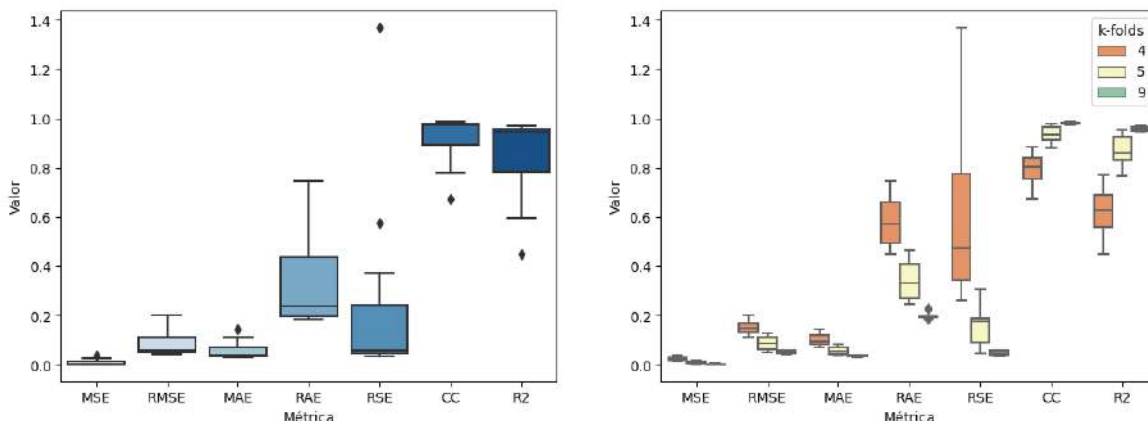


Figura 7.33: Validación cruzada modelo 6, prueba 10.

Los resultados de la validación cruzada en comparación de modelos de clasificación visual de la calidad (Tabla 7.15), modelos de predicción de la calidad (Tabla 7.16), y modelos de predicción de los parámetros de entrada (Tabla 7.17), se puede observar que los modelos que utilizan como base imágenes de superficie tienen un mejor rendimiento en todas las métricas, así como también una variación menor, lo que indica que estos modelos son más constantes ante diferentes grupos de entrenamiento y validación en comparación a los de imágenes termográficas.

Tabla 7.15: Comparación de validación cruzada modelos 1 y 2

Métrica	Modelo 1	Modelo 2
Exactitud (promedio)	0.9904	0.973
Exactitud (rango)	0.9555 - 1.000	0.887 - 1.000
Exactitud (desviación estándar)	0.0163	0.030
Presición (promedio)	0.9910	0.970
Presición (rango)	0.9555 - 1.000	0.888 - 1.000
Presición (desviación estándar)	0.0156	0.031
Recall (promedio)	0.9901	0.970
Recall (rango)	0.9555 - 1.000	0.888 - 1.000
Recall (desviación estándar)	0.0169	0.031
F1 score (promedio)	0.9905	0.970
F1 score (rango)	0.9555 - 1.000	0.888 - 1.000
F1 score (desviación estándar)	0.0163	0.031

Tabla 7.16: Comparación de validación cruzada modelos 3 y 4

Métrica	Modelo 3	Modelo 4
MSE (promedio)	0.000254	0.001139
MSE (rango)	0.000004 - 0.002921	0.000003 - 0.004481
MSE (desviación estándar)	0.000675	0.001428
RMSE (promedio)	0.010956	0.025521
RMSE (rango)	0.002099 - 0.054043	0.001715 - 0.066938
RMSE (desviación estándar)	0.011891	0.022712
MAE (promedio)	0.007979	0.018645
MAE (rango)	0.001344 - 0.037771	0.001375 - 0.047316
MAE (desviación estándar)	0.008349	0.016036
RAE (promedio)	0.062457	0.145424
RAE (rango)	0.011087 - 0.295742	0.011392 - 0.353818
RAE (desviación estándar)	0.065325	0.125944
RSE (promedio)	0.014308	0.061542
RSE (rango)	0.000231 - 0.173884	0.000160 - 0.228458
RSE (desviación estándar)	0.040215	0.079418
CC (promedio)	0.994261	0.975024
CC (rango)	0.927779 - 0.999923	0.904031 - 0.999944
CC (desviación estándar)	0.016783	0.033034
R2 (promedio)	0.987398	0.942865
R2 (rango)	0.853230 - 0.999772	0.794945 - 0.999839
R2 (desviación estándar)	0.033914	0.071731

Tabla 7.17: Comparación de validación cruzada modelos 5 y 6

Métrica	Modelo 5	Modelo 6
MSE (promedio)	0.0005335	0.0091296
MSE (rango)	0.0000097 - 0.0076663	0.0018791 - 0.0401736
MSE (desviación estándar)	0.0017860	0.0104105
RMSE (promedio)	0.0136200	0.0841312
RMSE (rango)	0.0031214 - 0.0875577	0.0433491 - 0.2004335
RMSE (desviación estándar)	0.0191941	0.0466070
MAE (promedio)	0.0090727	0.0564413
MAE (rango)	0.0020193 - 0.0530105	0.0299866 - 0.1446689
MAE (desviación estándar)	0.0116324	0.0320081
RAE (promedio)	0.0523802	0.3253848
RAE (rango)	0.0122563 - 0.3035617	0.1850894 - 0.7449021
RAE (desviación estándar)	0.0666824	0.1707358
RSE (promedio)	0.0098777	0.2114334
RSE (rango)	0.0001714 - 0.1457743	0.0344695 - 1.3686130
RSE (desviación estándar)	0.0340010	0.3253143
CC (promedio)	0.9959040	0.9245712
CC (rango)	0.9392003 - 0.9999371	0.6733550 - 0.9846637
CC (desviación estándar)	0.0141870	0.0872657
R2 (promedio)	0.9915560	0.8574563
R2 (rango)	0.8792773 - 0.9998307	0.4509023 - 0.9684693
R2 (desviación estándar)	0.0281222	0.1520367

Se realizaron evaluaciones de las piezas 480 (Figura 7.34), 189 (Figura 7.35), 474 (Figura 7.36), 371 (Figura 7.37), 385 (Figura 7.38) y 42 (Figura 7.39), para visualizar la clasificación y la predicción de los diferentes modelos.




Figura 7.34: Pieza 480, imágenes de superficie y termográfica.




Figura 7.35: Pieza 189, imágenes de superficie y termográfica.




Figura 7.36: Pieza 474, imágenes de superficie y termográfica.




Figura 7.37: Pieza 371, imágenes de superficie y termográfica.




Figura 7.38: Pieza 385, imágenes de superficie y termográfica.




Figura 7.39: Pieza 42, imágenes de superficie y termográfica.

Se realizó la comparación de clasificación de los modelos 1 y 2 en las categorías buena (Figura 7.40), mala (Figura 7.41) y con salpicadura (Figura 7.42). Se obtiene una clasificación perfecta en todas las piezas en el modelo 1.




Figura 7.40: Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría buena.




Figura 7.41: Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría mala.




Figura 7.42: Comparación de clasificación modelos 1 y 2, de predicción vs valor real, categoría salpicadura.

Para los modelos 3 y 4 se hizo la comparación de los valores reales contra la predicción de los parámetros de calidad fuerza de jalón (Figura 7.43), y diámetro de fusión (Figura 7.44).


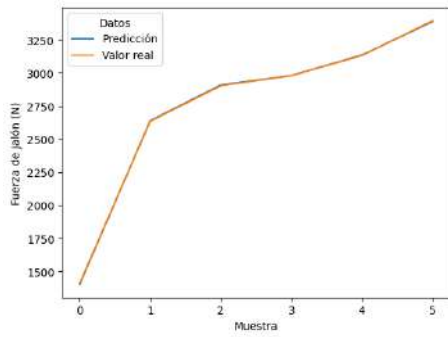


Figura 7.43: Comparación de predicción vs valor real de fuerza de jalón modelos 3 y 4.


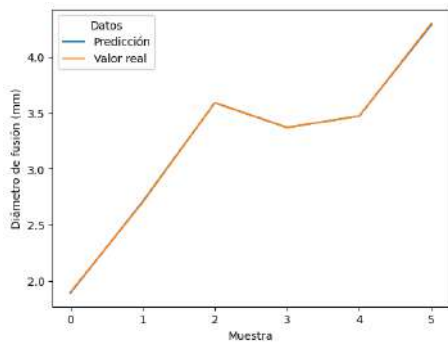


Figura 7.44: Comparación de predicción vs valor real de diámetro de fusión modelos 3 y 4.

Por último, en los modelos 5 y 6 se hizo la comparación de los valores reales contra la predicción de los parámetros de entrada: ángulo entre electrodos (Figura 7.45), Presión en el cilindro neumático (Figura 7.46), espesor (Figura 7.47), tiempo de soldadura (Figura 7.48), fuerza mínima registrada en los electrodos (Figura 7.49), fuerza máxima registrada en los electrodos (Figura 7.50), y corriente máxima obtenida en el proceso (Figura 7.51).




Figura 7.45: Comparación de predicción vs valor real de ángulo entre electrodos modelos 5 y 6.

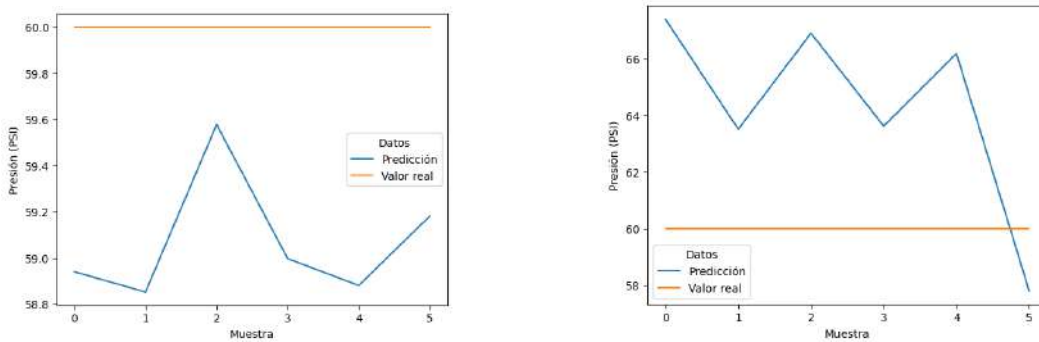


Figura 7.46: Comparación de predicción vs valor real de presión en el cilindro neumático modelos 5 y 6.




Figura 7.47: Comparación de predicción vs valor real de espesor modelos 5 y 6.





Figura 7.48: Comparación de predicción vs valor real de tiempo de soldadura modelos 5 y 6.





Figura 7.49: Comparación de predicción vs valor real de fuerza mínima registrada en los electrodos modelos 5 y 6.





Figura 7.50: Comparación de predicción vs valor real de fuerza máxima registrada en los electrodos modelos 5 y 6.





Figura 7.51: Comparación de predicción vs valor real de corriente máxima obtenida en el proceso modelos 5 y 6.

7.4. Discusión

Se determina que el parámetro de tiempo de soldado es el que tiene una mayor correlación con los parámetros de calidad de fuerza de jalón y diámetro de fusión. En fuerza medida durante el proceso de soldadura, se encuentra que las descripciones de fuerza mínima y máxima son los que tienen una mayor relación con los atributos de calidad. En la corriente medida durante el proceso, se observa que la corriente máxima registrada tiene la mayor correlación con los parámetros de la calidad. En relación con la medición de la fuerza, se observa una discrepancia máxima de 92 gramos en comparación con la media y una desviación estándar máxima de 7.022, lo que se traduce en un error mínimo, comparado con el rango de aplicación, el cual se encuentra en el rango de 5,000 a los 12,000 gramos. Por otro lado, la medida de corriente presenta una diferencia máxima de 0.18 amperes con respecto a la media, mientras que la desviación estándar máxima es de 0.226. Permitiendo obtener datos precisos y representativos.

La correlación de los parámetros de entrada muestra una mayor relación entre el tiempo de soldadura y los atributos de calidad de fuerza de tracción y diámetro de soldadura, seguidos de la corriente máxima durante el proceso y el ángulo entre electrodos. Por otro lado, la presión en el cilindro neumático no presenta correlación con los parámetros de calidad de la RSW.

Dentro de las arquitecturas probadas del estado del arte destaca el modelo de Lenet-5, que tiene el menor tiempo de predicción con respecto a los otros modelos. Este también cuenta con métricas de evaluación iguales o superiores a las demás arquitecturas en los 6 modelos definidos dentro del presente trabajo. Adicionalmente dentro en la búsqueda de hiperparámetros, se observa que la función de activación “relu” es la que obtiene mejores resultados.

Por otro lado, los modelos basados en imágenes de superficie tienen un mejor rendimiento en comparación con los basados en imágenes termográficas. Teniendo un mayor rendimiento medio en la validación cruzada, así como una menor desviación estándar, lo que indica que estos modelos tienen una repetibilidad constante en diferentes grupos de prueba.

7.5. Publicaciones

El presente trabajo de investigación genero dos publicaciones en revistas indexadas

- Artículo publicado en revista “La Mecatrónica en México” titulado “Instrumentación de Equipo de soldadura por Resistencia”.
- Artículo en revisión en revista “Data in Brief”, titulado “Resistance Spot Welding Insights: A Dataset Integrating Process Parameters, Infrared, and Surface Imaging”.

7.6. Trabajo futuro

Para futuras investigaciones, se propone

- Implementar los diferentes modelos de clasificación y predicción en un ambiente de producción utilizando un sistema embebido.
- Expandir las clasificaciones de los defectos y ponderarlos de acuerdo al severidad de falla.
- Utilizar filtros de escala de grises y contornos para el procesamiento de las imágenes.

Conclusión

Se presenta un banco de pruebas capaz de controlar y registrar los parámetros principales del proceso de soldadura por resistencia con un alto nivel de precisión y repetibilidad. Además, de tener la capacidad para medir sistemáticamente estos parámetros, permite identificar cualquier desviación o fallo en el proceso de soldadura, garantizando un resultado uniforme y de alta calidad.

Se creó una base de datos que integra los parámetros de construcción, el control de la corriente y la fuerza del electrodo, las características del material y los atributos de calidad relacionados con el punto de fusión. La cual fue utilizada en el entrenamiento de los diferentes modelos de clasificación y predicción de atributos de calidad de la soldadura por resistencia.

Los modelos desarrollados en el presente estudio demuestran una correlación con los parámetros de entrada y la calidad del punto de soldadura en sus atributos visuales y funcionales.

Basándonos en la información visual, se puede predecir atributos de calidad como la categoría, la fuerza de jalón y el diámetro de soldadura, así como los parámetros de construcción del proceso de soldadura por puntos con gran precisión.

Podemos concluir que los modelos que utilizan imágenes de superficie como entrada presentan una mayor precisión con respecto a las imágenes termográficas.

Los modelos propuestos en el presente trabajo muestran repetibilidad ante diferentes grupos de validación y prueba, por medio de la estrategia de validación cruzada, lo cual indica un alto grado de confiabilidad en la clasificación y predicción de estos modelos.

Se concluye que los modelos propuestos en el presente trabajo determinan la calidad del proceso de soldadura por resistencia, estableciendo una relación entre los parámetros del proceso, los atributos de calidad y las imágenes termográficas y de superficie obtenidas durante el proceso de soldadura por resistencia.

Bibliografía

- [1] R. Asari, “Resistance spot welding-weldability lobe simulation development,” *Sch J Appl Sci Res*, vol. 2, pp. 01–05, 2019.
- [2] D. W. Dickinson, J. E. Franklin, and A. Stanya, “Characterization of spot welding behavior by dynamic electrical parameter monitoring,” *Welding Journal*, vol. 59, p. 170, 1980.
- [3] C. Summerville, P. Compston, and M. Doolan, “A comparison of resistance spot weld quality assessment techniques,” *Procedia Manufacturing*, vol. 29, pp. 305–312, 2019.
- [4] M. Xiao, B. Yang, S. Wang, Z. Zhang, X. Tang, and L. Kang, “A feature fusion enhanced multiscale CNN with attention mechanism for spot-welding surface appearance recognition,” *Computers in Industry*, vol. 135, p. 103583, 2022.
- [5] P. R. Spena, M. D. Maddis, G. D’Antonio, and F. Lombardi, “Weldability and monitoring of resistance spot welding of Q&P and TRIP steels,” *Metals*, vol. 6, 11 2016.
- [6] J. Catty, “Development of an equipment to monitoring and control the quality of resistance welding,” *Journal of Acoustic Emission*, 2014.
- [7] W. Dai, D. Li, D. Tang, Q. Jiang, D. Wang, H. Wang, and Y. Peng, “Deep learning assisted vision inspection of resistance spot welds,” *Journal of Manufacturing Processes*, vol. 62, pp. 262–274, 2021.
- [8] American Welding Society (AWS), “Test methods for evaluating the resistance spot welding behavior of automotive sheet steel.” D8.9M:2012, 2012.
- [9] International Organization for Standardization (ISO), “Specification and qualification of welding procedures for metallic materials — welding procedure test — part 12: Spot, seam and projection welding.” ISO 15614-12:2021, 2021.
- [10] International Organization for Standardization (ISO), “Resistance welding — testing of welds — peel and chisel testing of resistance spot and projection welds.” ISO 10447:2015, 2015.
- [11] C. A. Gutiérrez, “Deep learning applied to welding diagnostics via plasma optical spectroscopy,” 2017.
- [12] T. Arunchai, K. Sonthipermpon, P. Apichayakul, and K. Tamee, “Resistance spot welding optimization based on artificial neural network,” *International Journal of Manufacturing Engineering*, pp. 1–6, 11 2014.

- [13] B. Xing, Y. Xiao, Q. H. Qin, and H. Cui, "Quality assessment of resistance spot welding process based on dynamic resistance signal and random forest based," *The International Journal of Advanced Manufacturing Technology*, vol. 94, pp. 327–339, 1 2018.
- [14] J. H. Kang and N. Ku, "Verification of resistance welding quality based on deep learning," *Journal of the Society of Naval Architects of Korea*, vol. 56, pp. 473–479, 2019.
- [15] D. Zhao, Y. Wang, D. Liang, and M. Ivanov, "Performances of regression model and artificial neural network in monitoring welding quality based on power signal," *Journal of Materials Research and Technology*, vol. 9, pp. 1231–1240, 3 2020.
- [16] D. Zhao, M. Ivanov, Y. Wang, and W. Du, "Welding quality evaluation of resistance spot welding based on a hybrid approach," *Journal of Intelligent Manufacturing*, vol. 32, pp. 1819–1832, 10 2021.
- [17] S. Lee, J. Nam, W. Hwang, J. Kim, and B. Lee, "A study on integrity assessment of the resistance spot weld by infrared thermography," *Procedia Engineering*, vol. 10, pp. 1748–1753, 2011.
- [18] A. E. Hernández, A. S. Roca, H. C. Fals, V. A. Ferraresi, and L. O. Vilarinho, "Influence of polarity on mechanical properties of dissimilar resistance spot welds of DP600/AISI 304 steels," *Science and Technology of Welding and Joining*, vol. 21, pp. 607–613, 2016.
- [19] J. Chen and Z. Feng, "Online resistance spot weld NDE using infrared thermography," *Non-destructive Characterization and Monitoring of Advanced Materials, Aerospace, and Civil Infrastructure 2017*, vol. 10169, 2017.
- [20] R. Veitía, E. Hernández, O. Vilarinho, S. Orozco, S. Roca, C. Fals, and J. Macias, "Deep learning for quality prediction in dissimilar spot welding DP600-AISI304, using a convolutional neural network and infrared image processing," *Proceedings of the 32nd European Modeling & Simulation Symposium (EMSS 2020)*, pp. 393–399, 2020.
- [21] J. Zhou, D. Wang, J. Chen, Z. Feng, B. Clarson, and A. Baselhuhn, "Autonomous nondestructive evaluation of resistance spot welded joints," *Robotics and Computer-Integrated Manufacturing*, vol. 72, p. 102183, 2021.
- [22] O. Martín, M. Pereda, J. I. Santos, and J. M. Galán, "Assessment of resistance spot welding quality based on ultrasonic testing and tree-based techniques," *Journal of Materials Processing Technology*, vol. 214, pp. 2478–2487, 2014.
- [23] H. Zhanfeng, W. Pei, X. Jing, and H. Jingyu, "Application of fractal theory in examination of resistance spot welding quality," *International Conference on Advanced Technology of Design and Manufacture (ATDM 2010)*, pp. 422–424, 2010.
- [24] S. G. Choi, I. Hwang, Y. M. Kim, B. Kang, and M. Kang, "Prediction of the weld qualities using surface appearance image in resistance spot welding," *Metals*, vol. 9, p. 831, 2019.
- [25] A. Abdulhadi, M. Gdeisat, and F. Lilley, "Assessing the quality of spot welding electrode tips using image processing techniques," *Proceedings of the World Congress on Engineering Vol II*, pp. 1557–1762, 2011.

- [26] International Organization for Standardization (ISO), “Welding for aerospace applications - resistance spot and seam welding.” ISO 16338:2017, 2017.
- [27] International Organization for Standardization (ISO), “Medical devices — quality management systems — requirements for regulatory purposes.” ISO 13485:2016, 2016.
- [28] N. Williams and J. Parker, “Review of resistance spot welding of steel sheets part 1 modelling and control of weld nugget formation,” *International Materials Reviews*, vol. 49, pp. 45–75, 2004.
- [29] Z. He and Q. Liu, “Deep regression neural network for industrial surface defect detection,” *IEEE Access*, vol. 8, pp. 35583–35591, 2020.
- [30] P. Bawankule and K. Chandrasekaran, “Analysis of rogowski coil shielding effectiveness with external vertical magnetic field using FEM,” *EasyChair*, 2023.
- [31] Q. Liang, J. Long, Y. Nan, G. Coppola, K. Zou, D. Zhang, and W. Sun, “Angle aided circle detection based on randomized hough transform and its application in welding spots detection,” *Mathematical Biosciences and Engineering*, vol. 16, pp. 1244–1257, 2019.
- [32] T. Dupuy and C. Srikunwong, “Resistance welding numerical simulation,” *Revue Européenne des Éléments Finis*, vol. 13, pp. 313–341, 2004.
- [33] Y. Chao, “Failure mode of spot welds: interfacial versus pullout,” *Science and Technology of Welding Joining*, vol. 8, pp. 133–137, 2003.
- [34] X. Sun, E. Stephens, R. Davies, M. Khaleel, and D. Spinella, “Effects of fusion zone size on failure modes and static strength of aluminum resistance spot welds,” *Weld J.*, vol. 83, 2004.
- [35] E. Alghannam, H. Lu, M. Ma, Q. Cheng, A. Gonzalez, Y. Zang, and S. Li, “A novel method of using vision system and fuzzy logic for quality estimation of resistance spot welding,” *Symmetry*, 2019.
- [36] I. Garrido, S. Lagüela, R. Otero, and P. Arias, “Thermographic methodologies used in infrastructure inspection: A review—post-processing procedures,” *Applied Energy*, vol. 266, p. 114857, 2020.
- [37] S. Y. Wang, Y. Zhao, and L. Wen, “PCB welding spot detection with image processing method based on automatic threshold image segmentation algorithm and mathematical morphology,” *Circuit World*, vol. 42, pp. 97–103, 2016.
- [38] K. He, G. Gkioxari, P. Dollár, and R. Girshick, “Mask R-CNN,” *IEEE international conference on computer vision*, pp. 2961–2969, 2017.
- [39] R. Girshick, “Fast R-CNN,” *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pp. 1440–1448, 2015.
- [40] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards real-time object detection with region proposal networks,” *Advances in Neural Information Processing Systems 28 (NIPS 2015)*, 2015.

- [41] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu, and A. C. Berg, “SSD: Single Shot MultiBox Detector,” *European Conference on Computer Vision*, vol. 9905, pp. 21–37, 2016.
- [42] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, real-time object detection,” *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788, 2016.
- [43] P. Sedgwick, “Pearson’s correlation coefficient,” *BMJ*, vol. 345, 2012.
- [44] M. Hossin and M. N. Sulaiman, “A review on evaluation metrics for data classification evaluations,” *International journal of data mining & knowledge management process*, vol. 5, no. 2, p. 1, 2015.
- [45] T. O. Hodson, “Root mean square error (rmse) or mean absolute error (mae): When to use them or not,” *Geoscientific Model Development Discussions*, vol. 2022, pp. 1–10, 2022.
- [46] M. A. A. Fernández, *Inteligencia artificial para programadores con prisa*. Universo de letras, 2021.
- [47] A. Botchkarev, “Evaluating performance of regression machine learning models using multiple error metrics in azure machine learning studio,” *Available at SSRN 3177507*, 2018.
- [48] V. Plevris, G. Solorzano, N. P. Bakas, and M. E. A. Ben Seghier, “Investigation of performance metrics in regression analysis and machine learning-based prediction models,” in *8th European Congress on Computational Methods in Applied Sciences and Engineering (ECCO-MAS Congress 2022)*, European Community on Computational Methods in Applied Sciences, 2022.
- [49] L. Domínguez, E. Rivas, J. Jáuregui, J. González, J. Pedraza, and A. Takacs, “Instrumentación de equipo de soldadura por resistencia,” *La Mecatrónica en México*, vol. 12, pp. 41–55, 2023.
- [50] R. Khwanrit, S. Kittipiyakul, J. Kudtonanggam, and H. Fujita, “Accuracy comparison of present low-cost current sensors for building energy monitoring,” *International Conference on Embedded Systems and Intelligent Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES)*, pp. 1–6, 2018.
- [51] Allegro MicroSystems, “ACS712, fully integrated, hall effect-based linear current sensor with 2.1 kvrms voltage isolation and a low-resistance current conductor,” *Allegro MicroSystems*, 2018.
- [52] L. Domínguez, “Resistance spot welding insights: A dataset integrating process parameters, infrared, and surface imaging,” *Mendeley*, 2023.
- [53] T. O’Malley, E. Bursztein, J. Long, F. Chollet, H. Jin, L. Invernizzi, *et al.*, “Kerastuner.” <https://github.com/keras-team/keras-tuner>, 2019.