



Universidad Autónoma de Querétaro
Facultad de Ingeniería

Clasificación de errores en rebabas de soldadura
por punto de una celda de manufactura robotizada
aplicando inteligencia artificial

Que como parte de los requisitos para obtener el grado
Maestro en Ciencias Mecatrónica.

Presenta:
Ing. Alfonso Alejo Ramírez

Dirigido por:
Dr. Irving Armando Cruz Albarrán

Co-Director:
Dr. Luis Alberto Morales Hernández

San Juan del Río, Qro. a 05 de Julio

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



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

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

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

Bajo los siguientes términos:

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

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

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

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

Avisos:

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

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



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias (Mecatrónica)



"Clasificación de errores en rebabas de soldadura por punto de una celda de manufactura robotizada aplicando inteligencia artificial"

Opción de titulación
TESIS

Que como parte de los requisitos para obtener el grado de Maestro en Ciencias de la Mecatrónica

Presenta:
Ing. Alfonso Alejo Ramírez

Dirigido por:
Dr. Irving Armando Cruz Albarrán

Co-Dirigido por:
Dr. Luis Alberto Morales Hernández

Dr. Irving Armando Cruz Albarrán
Presidente

Dr. Luis Alberto Morales Hernández
Secretario

Dr. Gerardo Israel Pérez Soto
Vocal

Dr. Emmanuel Reséndiz Ochoa
Suplente

Dr. Martín Valtierra Rodríguez
Suplente

Campus San Juan del Río, Querétaro
Julio 2024, México

RESUMEN

En México el proceso de la soldadura por punto (RSW) desempeña un papel fundamental en la fabricación de carrocerías y componentes automotrices. Grandes compañías automotrices, tanto nacionales como internacionales, tienen plantas de producción en México que emplean la soldadura por punto en sus procesos de fabricación, por lo tanto, la detección temprana de rebabas en la soldadura por punto es importante para corregir el problema, de acuerdo con la norma ISO 18278-2:2017 (porcentaje permitido de los defectos RSW), se estima el 1% de defectos permitidos en el chasis del automóvil, la inspección visual y, en algunos casos, pruebas destructivas o no destructivas pueden utilizarse para identificar las rebabas y tomar las medidas necesarias para eliminarlas. Debido a la producción en masa de vehículos automotores en México, se plantea una metodología capaz de identificar el tipo de defecto de la soldadura por punto por resistencia eléctrica (RSW) utilizando técnicas de visión artificial, aprendizaje automático, reconocimiento de patrones y análisis discriminante lineal (LDA). Esta metodología desarrollada consta de 6 pasos: 1) seleccionar imágenes digitales existentes en una base de datos que contienen puntos RSW, se utilizan técnicas de procesamiento de imágenes para identificar estos puntos. 2) Identificar las clases obtenidas a través de las similitudes entre imágenes utilizando un umbral óptimo para cada clase. 3) Realizar un aumento de datos para obtener una variabilidad en el número de muestras. 4) Aplicar la técnica LDA que permite separar las clases obtenidas. 5) Utilizar un modelo de aprendizaje para identificar la clasificación de estas clases. Y finalmente el último paso obtener una interfaz gráfica de usuario (GUI), donde se apliquen los pasos anteriores, el cual permitirá validar la metodología a partir del porcentaje de clasificación en las pruebas para identificar los puntos RSW. En las pruebas realizadas en la GUI para identificar imágenes RSW se obtuvo un porcentaje del 99.0% de clasificación, con este porcentaje alto de clasificación se concluye que la metodología propuesta es eficiente para detectar defectos en imágenes RSW, sin

embargo, para generalizar la metodología es necesario aumentar el número de clases con la finalidad de comparar resultados.

Palabras clave: Visión artificial, red neuronal, LDA, soldadura por punto por resistencia eléctrica (RSW), inteligencia artificial, reconocimiento de patrones.

SUMMARY

In Mexico, the process of Resistance Spot Welding (RSW) plays a crucial role in the manufacturing of car bodies and automotive components. Major automotive companies, both national and international, have production plants in Mexico that employ spot welding in their manufacturing processes. Therefore, the early detection of burrs in spot welding is important to correct the problem. According to ISO 18278-2:2017 (the allowed percentage of RSW defects), an estimated 1% of defects are permitted in the car chassis. Visual inspection, and in some cases, destructive or non-destructive testing can be used to identify burrs and take the necessary steps to eliminate them. Due to the mass production of motor vehicles in Mexico, a methodology capable of identifying the type of defect in Resistance Spot Welding (RSW) using artificial vision techniques, machine learning, pattern recognition, and linear discriminant analysis (LDA) is proposed. This developed methodology consists of six steps: 1) selecting existing digital images in a database that contain RSW points, where image processing techniques are used to identify these points. 2) Identifying the classes obtained through similarities between images using an optimal threshold for each class. 3) Performing data augmentation to achieve variability in the number of samples. 4) Applying the LDA technique to separate the obtained classes. 5) Using a learning model to identify the classification of these classes. And finally, the last step involves obtaining a graphical user interface (GUI) where the previous steps are applied, allowing the methodology to be validated based on the classification percentage in tests to identify RSW points. In tests conducted in the GUI to identify RSW images, a classification percentage of 99.0% was obtained. With this high classification percentage, it is concluded that the proposed methodology is efficient in detecting defects in RSW images. However, to generalize the methodology, it is necessary to increase the number of classes to compare results.

Keywords: Artificial vision, neural network, LDA, resistance spot welding (RSW), artificial intelligence, pattern recognition.

DEDICATORIA

Dedico este trabajo a mis padres y hermanos por su incondicional apoyo y amor, quienes siempre han creído en mí y me han impulsado a alcanzar mis sueños. A mi asesor de tesis el Dr. Irving Armando Cruz Albarrán y al Dr. Luis Alberto Morales Hernandez, por su guía y sabiduría, que han sido fundamentales en el éxito de este proyecto de investigación.

A mis amigos, por su compañía y ánimo constante, haciendo de este viaje una experiencia enriquecedora y memorable.

Y finalmente, a todos aquellos que de alguna manera contribuyeron a la realización de este proyecto, su apoyo ha sido invaluable.

AGRADECIMIENTOS

Agradezco a mis padres, quienes siempre han sido mi inspiración y apoyo incondicional a lo largo de este arduo camino. A mis hermanos, por su amor, comprensión y aliento constante. A mi director de tesis el Dr. Irving Armando Cruz Albarrán y al Dr. Luis Alberto Morales Hernández que gracias a sus consejos, enseñanzas y confianza por permitirme formar parte de su grupo de investigación fue posible desarrollar mi proyecto de tesis de maestría de manera satisfactoria.

Agradezco a mis profesores y sinodales por brindarme su conocimiento, apoyo constante y su dedicación en la revisión del presente documento.

Al Consejo Nacional de Humanidades, Ciencias y Tecnología por darme la oportunidad de obtener una beca de posgrado, que gracias a este incentivo pude realizar mis estudios de maestría.

ÍNDICE

| | |
|---|----|
| RESUMEN | 1 |
| SUMMARY | 3 |
| DEDICATORIA | 4 |
| AGRADECIMIENTOS | 5 |
| ÍNDICE..... | 6 |
| ÍNDICE DE FIGURAS..... | 8 |
| ÍNDICE DE TABLAS..... | 9 |
| 1. INTRODUCCIÓN | 10 |
| 1.1. Antecedentes | 11 |
| 1.2. Descripción del problema | 16 |
| 1.3. Justificación | 17 |
| 1.4. Hipótesis y objetivos..... | 18 |
| 1.4.1. Hipótesis | 18 |
| 1.4.2. Objetivo general..... | 18 |
| 1.4.3. Objetivos específicos | 19 |
| 1.5. Planteamiento general | 20 |
| 2. FUNDAMENTACIÓN TEÓRICA..... | 21 |
| 2.1. Soldadura por punto | 21 |
| 2.2. Visión Artificial..... | 24 |
| 2.2.1. Formación y representación de la imagen | 25 |
| 2.2.2. Procesamiento de imágenes..... | 26 |
| 2.2.3. Umbralización | 27 |
| 2.2.4. Binarización | 27 |
| 2.2.5. Filtrado | 27 |
| 2.2.6. Segmentación | 28 |
| 2.2.7. Erosión binaria | 29 |
| 2.2.8. Dilatación | 29 |
| 2.2.9. Segmentación basada en umbralización | 29 |
| 2.3. Machine Learning..... | 30 |
| 2.3.1. Aumento de datos | 30 |
| 2.3.2. Aprendizaje no supervisado | 32 |

| | |
|--|----|
| 2.3.3. Aprendizaje supervisado Análisis Discriminante Lineal..... | 32 |
| 2.4. Redes neuronales convolucionales | 35 |
| 2.5. Software de código libre | 39 |
| 2.5.1. Python | 39 |
| 3. METODOLOGÍA..... | 41 |
| 3.1. Base de datos | 42 |
| 3.2. Identificación de clases de defectos RSW..... | 43 |
| 3.3. Aumento de datos a partir del procesamiento de imágenes..... | 44 |
| 3.4. Aplicar LDA para distinguir las clases de los tipos de defectos de soldadura | 44 |
| 3.5. Modelo de aprendizaje automático..... | 46 |
| 3.6. Visualización y validación del error de soldadura del tipo rebaba | 47 |
| 4. RESULTADOS | 48 |
| 4.1. Base de datos | 49 |
| 4.2. Identificación de clases RSW..... | 50 |
| 4.3. Aumento de datos a partir de transformaciones geométricas y ajuste de intensidad..... | 51 |
| 4.4. Separación de clases con la técnica LDA..... | 52 |
| 4.5. Modelo de aprendizaje | 58 |
| 4.5.1. Aplicación de la metodología en la GUI | 61 |
| 5. CONCLUSIONES | 69 |
| 6. PROSPECTIVAS | 71 |
| REFERENCIAS..... | 72 |
| APENDICES | 76 |
| Apéndice A Algoritmo desarrollado..... | 76 |
| Apéndice B Discusión de clasificación RSW | 77 |
| Apéndice C Artículo publicado | 78 |

ÍNDICE DE FIGURAS

| | |
|--|----|
| Figura 1.1 Planteamiento general (Autoría propia)..... | 20 |
| Figura 2.1 Esquema general de RSW (autoría propia)..... | 22 |
| Figura 2.2 Defectos RSW (Dai et al., 2022). | 24 |
| Figura 2.3 Etapas del proceso de visión artificial (autoría propia)..... | 25 |
| Figura 2.4 Separación de clases (Autoría propia). | 32 |
| Figura 2.5 Red neuronal convolucional (Autoría propia)..... | 36 |
| Figura 2.6 Matriz de confusión (Autoría propia)..... | 38 |
| Figura 3.1 Metodología (autoría propia)..... | 41 |
| Figura 3.2 Imágenes RSW Dai et al. (2022)..... | 42 |
| Figura 3.3 ROI imágenes RSW Dai et al. (2022)..... | 43 |
| Figura 3.4 Proceso LDA (Autoría propia)..... | 45 |
| Figura 3.5 Interfaz de usuario (Autoría propia). | 47 |
| Figura 4.1 Proceso para obtener una imagen RSW punto bueno (autoría propia)..... | 49 |
| Figura 4.2 Proceso para obtener una imagen RSW punto malo (autoría propia) | 50 |
| Figura 4.3 Proceso para obtener una imagen RSW doble punto (autoría propia) | 50 |
| Figura 4.4 Imagen transformada (Autoría propia)..... | 52 |
| Figura 4.5 Ventaneo de imagen (Autoría propia)..... | 53 |
| Figura 4.6 Características que describen la clase RSW punto bueno (Autoría propia) | 54 |
| Figura 4.7 Características que describen la clase RSW punto malo (Autoría propia)..... | 54 |
| Figura 4.8 Características que describen la clase RSW doble punto (Autoría propia)..... | 55 |
| Figura 4.9 Proceso de separación de clases (Autoría propia) | 55 |
| Figura 4.10 Proyección en dos dimensiones (Autoría propia) | 56 |
| Figura 4.11 Características seleccionadas (Autoría propia) | 56 |
| Figura 4.12 Proyección en dos dimensiones (Autoría propia) | 57 |
| Figura 4.13 Proyección en 3 dimensiones (Autoría propia) | 58 |
| Figura 4.14 Modelo de aprendizaje (Autoría propia) | 59 |
| Figura 4.15 Entrenamiento K-fold (Autoría propia)..... | 60 |
| Figura 4.16 Validación K-fold (Autoría propia)..... | 61 |
| Figura 4.17 Diseño preliminar de la GUI (Autoría propia)..... | 61 |
| Figura 4.18 Diseño final de la GUI (Autoría propia)..... | 62 |
| Figura 4.19 Testeo de imagen punto bueno en la GUI (Autoría propia) | 63 |
| Figura 4.20 Testeo de imagen punto malo en la GUI (Autoría propia)..... | 64 |
| Figura 4.21 Testeo de imagen doble punto en la GUI (Autoría propia) | 65 |
| Figura 4.22 GUI en la aplicación industrial automotriz (Autoría propia) | 67 |

ÍNDICE DE TABLAS

| | |
|--|----|
| Tabla 2.1 Características en imágenes RSW (Zhang & Senkara, 2017) | 33 |
| Tabla 3.1 Proceso para obtener una imagen RSW | 42 |
| Tabla 3.2 Distribución de clases base de datos..... | 44 |
| Tabla 3.3 Base de datos aumentada..... | 44 |
| Tabla 4.1 Matriz de pruebas | 49 |
| Tabla 4.2 Umbral óptimo de las clases de imágenes RSW | 51 |
| Tabla 4.3 Base de datos original..... | 51 |
| Tabla 4.4 Base de datos aumentada..... | 52 |
| Tabla 4.5 Resultados de la matriz de pruebas..... | 66 |
| Tabla 4.6 Ventajas y desventajas de la metodología propuesta | 68 |

1.INTRODUCCIÓN

En México el proceso de la soldadura por punto desempeña un papel fundamental en la fabricación de carrocerías y componentes automotrices. De acuerdo con las estimaciones de la Asociación Mexicana de la Industria Automotriz (AMIA), al 2022 México ha producido aproximadamente 40 millones de vehículos, del cual cada auto contiene de 2000 a 3000 puntos de soldadura (dependiendo del tamaño). A este ritmo de producción es necesario desarrollar una metodología que sea capaz de reconocer y clasificar los puntos de soldadura de acuerdo con las características específicas de cada punto, de modo que se pueda evitar fallas estructurales, problemas de seguridad, tiempo de unión en las placas soldadas, la estética y calidad del punto.

En esta tesis se describe el desarrollo de una metodología basada en procesamiento de imágenes, reconocimiento de patrones e inteligencia artificial, a partir de una muestra de una base de datos de imágenes digitales que contienen errores de soldadura por punto obtenidas de una celda de manufactura robotizada. El trabajo contiene cinco secciones, además de las Referencias y Apéndices. En el capítulo I se introduce la importancia del proceso de la soldadura por punto, los Antecedentes, Descripción del problema, Justificación y Planteamiento general, que generaron el presente tema de investigación; además de los objetivos para concluir satisfactoriamente con la metodología. En el capítulo II se muestra la fundamentación teórica que sustenta el desarrollo del presente trabajo. En el capítulo III se muestra la metodología propuesta para la clasificación de defectos en imágenes RSW el cual constó de 6 pasos. El capítulo IV muestra los resultados que se obtuvieron al aplicar la metodología propuesta, finalmente se incluye el apartado de conclusiones, prospectivas, referencias y los apéndices.

1.1. Antecedentes

La soldadura por punto es ampliamente utilizada en la industria automotriz, especialmente para unir partes de carrocería, además de ser empleada en la fabricación de electrodomésticos, muebles metálicos y otros productos de metal. Este método de soldadura ofrece varias ventajas, como alta velocidad de producción, buena resistencia de unión, cantidad mínima de material de soldadura y a diferencia de los otros procesos de soldadura genera una pequeña zona afectada. Sin embargo, a pesar de los procesos de control e inspección manual, puede generar rebaba en algunos puntos de unión. De esta forma ha surgido la necesidad de investigación y desarrollo en el proceso de la soldadura por punto, como se menciona en los siguientes trabajos.

En su investigación Alghannam et al. (2019) mencionaron que la soldadura por punto es usada ampliamente como método de unión en las industrias automotrices, debido a sus ventajas de bajo costo, alta eficiencia y facilidad de operación automática. En las líneas de montaje de carrocerías de gran volumen y gran velocidad, las incertidumbres en la fabricación, como las fluctuaciones de presión entre electrodos, el desgaste de los electrodos y las superficies contaminadas de las piezas de trabajo, degradarían la calidad de la soldadura y aumentaría la probabilidad de fallo o errores de las soldaduras por punto. Por otro lado, Sanghadiya & Mistry (2015) recomendaron que es importante desarrollar técnicas no destructivas para la inspección de la calidad de la soldadura por puntos y corrección o recomendaciones inmediatas para mejorar la misma. En los últimos años, se ha alcanzado un gran avance en la detección visual automática de soldaduras por punto basada en la visión artificial y el aprendizaje automático como técnicas complementarias. De esta manera se buscan técnicas de procesamiento de imágenes, como la umbralización por el método otsu, morfología matemática y filtros con texturas para la detección de puntos de soldadura. De ahí que, Bravo (2015) desarrolló un software para identificar los errores que generan la soldadura gas inerte de metal, (MIG/MAG por sus siglas en inglés Metal Inter Gas, Metal Active Gas) en piezas metálicas mediante visión artificial aplicando morfología matemática,

umbral por método otsu y segmentación. Con ayuda de filtros e interpretación de los mismos datos identificó la porosidad y de esta forma determinó si la soldadura era aceptable o inaceptable, sin obtener alguna clasificación del tipo errores en rebabas. De manera similar, Alghannam et al. (2019) utilizaron procesos de segmentación y umbralización para estimar la calidad de la soldadura por puntos, su método se basó en estructurar la imagen para no perder datos de interés cuando la imagen se erosiona o se dilata. De esta forma obtuvieron datos que los interpretaron como características geométricas, que utilizaron en un modelo 3D que calcula el tamaño de la rebaba, esto lo aplicaron para definir once funciones difusas que estiman la calidad de la soldadora por punto.

Según Hussain et al. (2021) indican que la inspección visual puede automatizarse con un sistema de visión que consiste en cámaras digitales y un ordenador con una interfaz especial de procesamiento de imágenes. La caracterización de regiones son requisitos previos para las tareas de visión por ordenador. En comparación con los métodos convencionales que consumen mucho tiempo y son menos robustos, los métodos de aprendizaje profundo (Deep Learning) y aprendizaje de máquina (Machine Learning) aumentaron drásticamente el rendimiento de la extracción de características en las regiones de interés especialmente para los casos con bases de datos a gran escala. De esta manera se realizaron estudios para extraer las características o regiones de interés, como el estudio realizado por Dai et al. (2021) donde mostraron las redes antagónicas generativas (GAN's por sus siglas en inglés Generative Adversarial Networks) como un método eficaz para generar muestras de datos artificiales para clases menores de un conjunto de imágenes. Con esto mejoraron el rendimiento de la clasificación de defectos de soldadura por puntos mediante el uso de aumento de datos basado en GAN's, para después construir un clasificador de imágenes con una red neuronal profunda pre-entrenada que emplea un método de aprendizaje por transferencia. Con este método analizaron los defectos de las soldaduras por puntos y las clasificaron en seis tipos que han sido caracterizados y anotados por un experto. Por otro lado, Dai et al. (2022) propusieron un modelo de red para la detección de objetos pequeños donde detectaron la posición y la calidad de la soldadura por

puntos. El cual se basó en el modelo You Only Look Once (YOLOv3 por sus siglas en inglés) pero con tres mejoras novedosas. En primer lugar, se presentó la red liviana MobileNetV3 para reemplazar la red troncal de YOLOv3 para garantizar la precisión y el rendimiento en tiempo real. En segundo lugar, mejoraron la capacidad del modelo para la detección de objetos pequeños mediante la propuesta de una nueva red piramidal de características (FPN por sus siglas en inglés Feature Pyramid Network) con conexiones eficientes entre escalas, que permite una fusión de características multiescala fácil y rápida. Finalmente, consideraron las deficiencias de la intersección y la pérdida de relación de unión (por sus siglas en inglés IoU), que utiliza la pérdida completa de IoU (ClIoU) para mejorar la velocidad de convergencia y la precisión de la regresión. Además, utilizaron un nuevo aumento de muestras para enriquecer el conjunto de datos durante el entrenamiento del modelo. Los resultados cuantitativos en el conjunto de datos de soldadura por puntos mostraron que el enfoque que propusieron logró resultados exitosos para la inspección visual de soldadura por puntos por resistencia.

La construcción de clasificadores de errores de soldadura basado en los métodos de aprendizaje por redes neuronales, redes neuronales convolucionales y aprendizaje profundo han sido de gran interés para los investigadores al conseguir una alta precisión en la clasificación de errores o puntos defectuosos. En su trabajo Ye et al. (2017) desarrollaron un sistema de inspección por visión, que reconoció los defectos de soldadura en componentes electrónicos basado en una red neuronal. Primero, las imágenes de soldadura son adquiridas por una cámara a color. Luego, extrajeron 15 características de las imágenes de soldadura que habían sido corregidas y mejoradas. Finalmente, usaron 1800 muestras de entrenamiento para la red neuronal. Y obtuvieron una precisión del 95,82 % en 407 muestras de prueba del clasificador de redes neuronales, que tenía 15 capas de entrada, 4 capas ocultas y 2 capas de salida. Otro trabajo importante es el de Wang et al. (2017) donde utilizaron una red neuronal recurrente modificada para estimar el tamaño de la zona afectada de la soldadura por punto por el calor, usaron un novedoso clasificador de tipo de mapa autoorganizado para detectar la condición de expulsión junto con su tiempo de ocurrencia. En sus experimentos de soldadura por puntos, el porcentaje

de error promedio de la estimación del tamaño de la zona afectada por el calor es de alrededor del 6,7 % y la precisión en la detección de la expulsión alcanza el 93,3 %. Así mismo, Yang et al. (2018) desarrollaron un método novedoso basado en la técnica de aprendizaje por transferencia para clasificar los productos de soldadura por puntos de acuerdo con sus imágenes de unión de soldadura. Usaron GoogLeNet para extraer las características de la imagen de unión de soldadura, que está pre-entrenada en ImageNet. Luego utilizaron un perceptrón multicapa (MLP) para clasificar estas imágenes. El método logró una precisión de clasificación final del 96,99 % en un conjunto de pruebas que incluía 334 imágenes. Después, en el trabajo de Younes et al. (2020) se emplearon métodos mejorados de procesamiento de imágenes para extraer características de la superficie de la rebaba de soldadura de forma elíptica para obtener un modelo tridimensional, con el propósito de reconstruir la superficie de la soldadura. Con estos resultados utilizaron el método de máquina de vectores de soporte difuso (FSVM por sus siglas en inglés Fuzzy Support Vector Machines) que está formado por funciones de pertenencia difusa, que mostró un buen rendimiento en la clasificación de los errores de calidad de la soldadura por puntos.

Por otra parte, es importante mencionar que, dentro de la Universidad Autónoma de Querétaro se han desarrollado múltiples trabajos de investigación que utilizan procesamiento de imágenes en conjunto con algoritmos de inteligencia artificial para la solución de una problemática específica en el área de ingeniería. Por ejemplo, Valtierra-Rodriguez et al. (2020) utilizaron una metodología basada en redes neuronales convolucionales (CNN) y el filtro tiempo-frecuencia basado en la transformada de Fourier de tiempo corto (STFT) para la detección automática de fallas en motores de inducción. Aplicaron la STFT con superposición y ventana gaussiana, de esta manera encontraron el patrón en forma de V en el plano de tiempo-frecuencia, mejorando la resolución de tiempo y reduciendo el efecto de fuga. Finalmente, los planos de tiempo-frecuencia se trataron como imágenes y entradas a la CNN 2D, teniendo como resultado el 100% de precisión en la detección automática de barras rotas del rotor en motores de inducción. Por su parte Reséndiz-Ochoa et al. (2022) obtuvieron una metodología para el diagnóstico de

fallas en motores de inducción con técnicas de termografía infrarroja no segmentada. Para ello, tomaron directamente del termograma características estadísticas significativas que describen el comportamiento térmico del sistema electromecánico, luego minimizaron el conjunto de características y, a través de un algoritmo de aprendizaje automático clasificaron tres condiciones de falla: una barra rota, daños en los cojinetes y desalineamiento. Otro trabajo importante, es el de Alvarado-Hernandez et al. (2022) en el cual desarrollaron un sensor inteligente basado en termografía para el diagnóstico de fallas en rodamientos y cajas de cambios de los motores de inducción, el cual cuenta con cinco partes principales: un sensor primario de infrarrojos, un módulo de preprocesamiento, un módulo de procesamiento de imágenes, clasificación de fallas y una interfaz de usuario. Incluyeron una microcámara térmica de bajo costo en el sensor primario de infrarrojos, en el módulo de procesamiento y el módulo de clasificación implementaron algoritmos de procesamiento de datos, el cual contiene características del sistema inteligente. Finalmente, el módulo de interfaz permitió a los usuarios la visualización de datos ya que presenta un informe de diagnóstico, que se validó con un banco real de pruebas experimental, de esta forma demostraron las capacidades del sensor inteligente ante diferentes casos de estudio. Finalmente, Diaz-Saldaña et al. (2023) desarrollaron una metodología no invasiva basada en la fusión de señales y el acabado superficial de las piezas mecanizadas del motor y el husillo de un torno CNC para la clasificación del desgaste. Para ello, utilizaron métodos estadísticos y no estadísticos, indicadores de reducción de dimensionalidad por análisis discriminante lineal (LDA) y una red neuronal feed-forward (FFNN), con lo cual obtuvieron una eficiencia del 95% del desgaste de la herramienta, y un 82.84% para la velocidad de avance de la herramienta.

De acuerdo con los antecedentes presentados anteriormente existe la oportunidad de desarrollar metodologías de clasificación específicamente en el tema de la soldadura por punto de los errores del tipo rebaba, además de reducir el tiempo de procesamiento y carga computacional en los algoritmos de segmentación, reconocimiento de patrones y clasificación. De esta forma se

presenta el desarrollo de una metodología que permitirá clasificar dos clases de errores del tipo rebaba (fuera del borde y dentro del borde), algoritmos de segmentación, reconocimiento de patrones basado en técnicas de inteligencia artificial y procesamiento de imágenes que reduzcan el tiempo de procesamiento, carga computacional y mayor sensibilidad en la obtención de los datos de interés.

1.2. Descripción del problema

De acuerdo con las estimaciones de la Asociación Mexicana de la Industria Automotriz (AMIA), al 2022 México ha producido aproximadamente 40 millones de vehículos. A este ritmo de producción es necesario aplicar un sistema de visión automática para la inspección visual de los defectos de errores de soldadura por punto de modo que se puedan evitar fallos en la estructura de la placa soldada, problemas de seguridad y durabilidad al identificar defectos y calidad de la soldadura. Por otra parte, al no identificar fallos o defectos en la soldadura se puedan identificar como punto bueno.

En los trabajos de Bravo (2015) y Alghannam et al. (2019), se usaron flancos de disparo manual y valores por defecto para la adquisición de imágenes, esto puede generar perdida de información, así mismo no son robustos ante diferentes condiciones de iluminación. Además de generar una carga computacional muy alta por utilizar procesamiento de imágenes con una gran cantidad de operaciones de procesamiento, el cual implica un gran número de cálculos matemáticos complejos, tales como la detección de bordes, la segmentación y la clasificación de objetos. Al utilizar grandes procesos de datos y cálculos matemáticos se necesita de hardware con costo muy elevado, de tal forma es necesario utilizar técnicas que reduzcan el uso de hardware, cálculos matemáticos y tiempo de procesamiento.

El alto uso de la soldadura por punto en las celdas de manufactura ha ocasionado que existan avances en el control de calidad por medio de trabajos inmediatos que permitan reducir los errores de la soldadura del tipo rebaba. Sin embargo, aún existen protuberancias no deseadas que pueden formarse en los

bordes de las piezas soldadas. Estos pueden ser causados por parámetros incorrectos de soldadura, lo cual afecta directamente la calidad y eficiencia. Además de las rebabas que pueden existir, la ubicación de los puntos de soldadura puede estar en una posición incorrecta, que puede producir deformaciones y distorsión en las piezas de ensamble, de este modo se generan desperdicios tóxicos y pérdida de material. Por lo que en el presente trabajo se desarrollará una metodología automática para la clasificación de soldadura por punto con errores del tipo rebaba, a partir de una base de datos de imágenes que contienen los mismos errores, técnicas de inteligencia artificial aplicado a procesamiento de imágenes y reconocimiento de patrones.

1.3. Justificación

En la presente investigación se desarrollará una metodología automática para la clasificación de errores del tipo rebaba en puntos de soldadura, a partir de imágenes digitales obtenidas de una celda de manufactura robotizada aplicando procesamiento de imágenes, técnicas basadas en el reconocimiento de patrones con inteligencia artificial. Es decir, esta propuesta de proyecto consiste en desarrollar una metodología capaz de aprender a reconocer y clasificar puntos en imágenes de soldadura por punto de manera precisa y eficiente, a partir de un conjunto de datos de entrenamiento previamente etiquetado, esto con la finalidad de reducir carga computacional de la metodología y tiempo en el preprocesamiento de datos, de modo que la metodología desarrollada pueda formar parte de un sistema mecatrónico de visión artificial.

Como lo menciona Hussain et al. (2021) utilizar técnicas de inteligencia artificial reduce el procesamiento de datos en el hardware, el cual se aplicará en el desarrollo de algoritmos y técnicas de procesamiento de imágenes que sean capaces de detectar y reconocer objetos, que sean robustos ante diferentes condiciones de iluminación y eficientes en términos de tiempo y recursos computacionales. Para detectar y registrar incluso los defectos más pequeños y sutiles en las soldaduras, lo que garantiza una mayor precisión en el proceso de inspección. Al utilizar algoritmos de inteligencia artificial en la metodología para la

clasificación de soldadura por punto con errores del tipo rebaba, puede adaptarse y modificar los valores para las distintas condiciones de iluminación, esto reduce la perdida de información y obtiene imágenes con menor ruido, además con el uso de disparos automáticos se reducirá el tiempo de adquisición y garantizará la correcta adquisición de imagen de una nueva pieza. Al aplicar algoritmos que detecten desviaciones en el tamaño, posición y forma de los puntos de soldadura con errores del tipo rebaba se pueden prevenir defectos y asegurar que las soldaduras cumplan con los estándares de calidad requeridos. Así mismo, permitirá reducir el tiempo de configuración al detectar automáticamente la ubicación del punto de soldadura, de esta forma al reducir errores de deformaciones en las piezas de ensamble, se contribuye de manera directa a una de las problemáticas existentes en los programas nacionales estratégicos establecidos por el CONAHCYT. Específicamente en el rubro de “Agentes tóxicos y procesos contaminantes”, ya que se reduce la pérdida de material y residuos tóxicos que afectan directamente al medio ambiente, manteniendo la defensa de los derechos ambientales.

1.4. Hipótesis y objetivos

1.4.1. Hipótesis

A partir de una base de datos de imágenes digitales que contienen errores de soldadura por punto obtenidas de una celda de manufactura robotizada, es posible obtener una metodología automática que segmente los puntos de soldadura, los caracterice y permita identificar si el punto de soldadura tiene errores del tipo rebaba, utilizando técnicas de procesamiento de imágenes, reconocimiento de patrones y aprendizaje automático.

1.4.2. Objetivo general

Desarrollar una metodología automática para la clasificación de errores del tipo rebaba en puntos de soldadura a partir de imágenes digitales obtenidas de una

celda de manufactura robotizada aplicando técnicas de procesamiento de imágenes, reconocimiento de patrones y aprendizaje automático.

1.4.3. Objetivos específicos

- Generar una muestra de una base de datos a partir de la adquisición de imágenes digitales que contengan errores de soldadura por punto del tipo rebaba que servirán como base para generar el algoritmo de caracterización.
- Desarrollar un algoritmo que pueda identificar los tipos de defectos RSW, que permita reducir la carga computacional, el tiempo de procesamiento y sea robusto ante diferentes condiciones de iluminación.
- Caracterizar los errores de soldadura por punto en regiones aplicando procesamiento de imágenes para entrenar una red neuronal de modo que pueda identificar patrones de cada error del tipo rebaba.
- Desarrollar un clasificador a través de técnicas de inteligencia artificial utilizando los patrones de cada error, para aplicarlo a imágenes distintas a la muestra de la base de datos y validar el clasificador.
- Desarrollar una interfaz gráfica de usuario en un software de código libre, con los algoritmos de reconocimiento de patrones, procesamiento de imágenes y caracterización, el cual permita visualizar la clasificación de la soldadura por punto con errores del tipo rebaba para validar la metodología obtenida.

1.5. Planteamiento general

En la Figura 1.1 se muestra el planteamiento general de la metodología para el desarrollo de la clasificación de la soldadura por punto del tipo rebaba. En esta se pueden visualizar los elementos requeridos para lograr el objetivo final.

Primero se obtendrá una base de datos que contenga imágenes con errores en soldadura por punto. En segundo se tiene la interfaz de usuario que contiene los algoritmos de segmentación, análisis y reconocimiento de la rebaba en los puntos de soldadura, el cual será la encargada de procesar y analizar la imagen de entrada. Finalmente, en la misma interfaz se visualizará los puntos de la imagen que contienen rebaba, los que tienen algún defecto y los puntos que se aplicaron correctamente.



Figura 1.1 Planteamiento general (Autoría propia).

2.FUNDAMENTACIÓN TEÓRICA

Este proyecto de tesis se basó en desarrollar una metodología de clasificación de los puntos de soldadura con errores del tipo rebaba, debido a los desperfectos que genera el proceso de la soldadura en la industria automotriz en México, a continuación, se describe la fundamentación teórica que sustenta y servirá como base para el desarrollo de la metodología. Inicialmente se describe el proceso y características de la soldadura por punto, las generalidades del uso de vision artificial en imágenes digitales, los conceptos y métodos de machine learning, por último, se mencionan los lenguajes de programación donde se puede desarrollar interfaces graficas de usuario con código libre.

2.1. Soldadura por punto

La soldadura por punto es un proceso de adherencia utilizado comúnmente en la industria para combinar dos o más piezas de metal (Figura 2.1). Se caracteriza por la formación de puntos de soldadura localizados en lugares específicos de las piezas a fundir, la unión se obtiene a partir de la fusión de los dos elementos de metal, lo cual produce energía calorífica que puede ser calculada mediante la ecuación 2.1. Este calor funde parcialmente las superficies de contacto, creando puntos de fusión, a medida que las piezas se enfrian, los puntos de fusión solidifican y se convierten en puntos de soldadura.

Se genera una fusión concentrada por cierta cantidad de calor (Q), la cual está determinada por la resistencia eléctrica del circuito (R) y el flujo de corriente al cuadrado (I) que fluye a través durante un intervalo de tiempo (t).

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

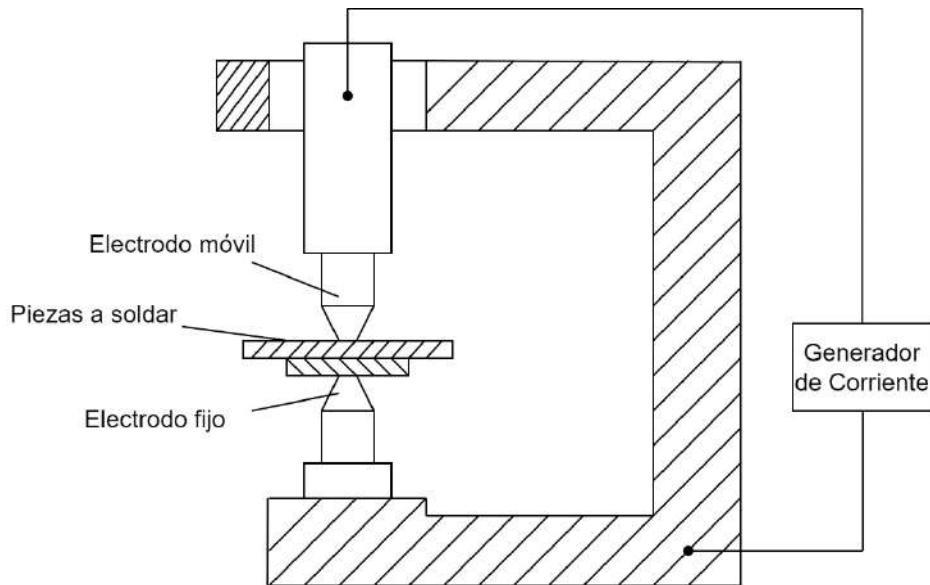


Figura 2.1 Esquema general de RSW (autoría propia).

El electrodo fijo y el electrodo móvil se aplican en distintas zonas de la chapa a soldar. El cual une chapas de espesores comprendidos entre 0.05 mm y 6 mm.

Mediante puntos se sueldan planchas superpuestas. Los dos electrodos están conectados al transformador secundario. La corriente eléctrica fluye a través del electrodo, superando la resistencia generada por las dos láminas superpuestas. Esto provoca que el área entre los electrodos se caliente debido al efecto Joule. Posteriormente, la corriente regresa al transformador y a su fuente de origen a través del electrodo. En el mismo punto de paso de corriente a través de las láminas y bajo la presión ejercida por los electrodos, se forma una soldadura por punto. El diámetro de esta soldadura depende de la superficie de los extremos de los electrodos y la duración del flujo de corriente de soldadura. Los componentes principales de una máquina de soldadura por puntos incluyen el armazón, el transformador encargado de suministrar la corriente de soldadura, el circuito secundario externo que conduce la corriente del transformador a los porta-electrodos y electrodos, un sistema para aplicar movimiento y presión a los electrodos (generando esfuerzo de compresión localizado en las piezas a soldar), un sistema de refrigeración para las partes sujetas a calentamiento durante el paso de corriente, y un conjunto de dispositivos eléctricos y electrónicos (Molera, 1992).

Los puntos más comunes de la RSW son: mal punto, doble punto, punto aceptable y pseudosoldaduras (Figura 2.2). Donde las características de cada punto son las siguientes:

a) Punto Bueno

- Forma y Tamaño Adecuados: Un punto bueno tiene una forma y tamaño específicos según los requisitos del diseño.
- Buena Penetración: El proceso de soldadura ha logrado una penetración adecuada en los materiales que se están uniendo.
- Buena Fuerza de Sujeción: El punto muestra una fuerza de sujeción satisfactoria, lo que garantiza la integridad estructural.
- Bajo Riesgo de Defectos: Carece de defectos visibles como grietas, porosidades o inclusiones.

b) Doble Punto

- Proximidad Adecuada: En algunos casos, puede ser necesario colocar dos puntos de soldadura cercanos para lograr una unión más fuerte.
- Distribución Uniforme de Calor: Es esencial que la distribución de calor entre los dos puntos sea uniforme para evitar deformaciones no deseadas.
- Coalescencia Controlada: La coalescencia entre los puntos debe ser controlada para evitar la formación de huecos o uniones débiles.

c) Punto Malo

- Forma Irregular o Inadecuada: Un punto malo puede tener una forma irregular o un tamaño inadecuado, lo que afecta la calidad de la unión.
- Penetración Insuficiente o Excesiva: Puede haber problemas con la penetración de la soldadura, ya sea insuficiente o excesiva.
- Defectos Visibles: Pueden presentarse defectos visibles como grietas, inclusiones de material no fundido o porosidades.
- Fuerza de Sujeción Deficiente: La fuerza de sujeción puede ser insatisfactoria, lo que afecta la resistencia de la unión.



Figura 2.2 Defectos RSW (Dai et al., 2022).

2.2. Visión Artificial

Es un campo que abarca todos los procedimientos y componentes que permiten dotar a una máquina de capacidades visuales. Significa la capacidad de una máquina para extraer automáticamente las características y propiedades de un entorno tridimensional, en constante cambio, mediante el análisis de imágenes planas. En visión artificial, se busca deducir tanto las características geométricas, como la forma, tamaño y ubicación de los objetos, como las características materiales, como el color, el contraste, la textura y la composición. Si las condiciones ambientales, como la cantidad de luz, se modifican durante la formación de la imagen, también se requerirá adaptar la interpretación de los cambios y, en algunos casos, incluso predecir el futuro comportamiento (Marcos et al., 2006).

El proceso de visión artificial consta de las siguientes etapas (Figura 2.3):

1. Captura de la imagen digital: Implica el uso de sensores y la capacidad de convertir la señal del sensor en datos digitales.
2. Preprocesamiento de la imagen: El objetivo final es aumentar la calidad de la imagen para mejorar las posibilidades de éxito.
3. Segmentación: Consiste en agrupar la imagen en partes u objetos que la componen. Una segmentación precisa facilita la resolución del problema. La salida de esta etapa es una imagen de datos que contiene la región de interés (por sus siglas en inglés ROI).

4. Reconocimiento e interpretación: Este proceso implica etiquetar o clasificar un objeto utilizando los descriptores disponibles. La comprensión implica otorgar significado al conjunto de objetos identificados.

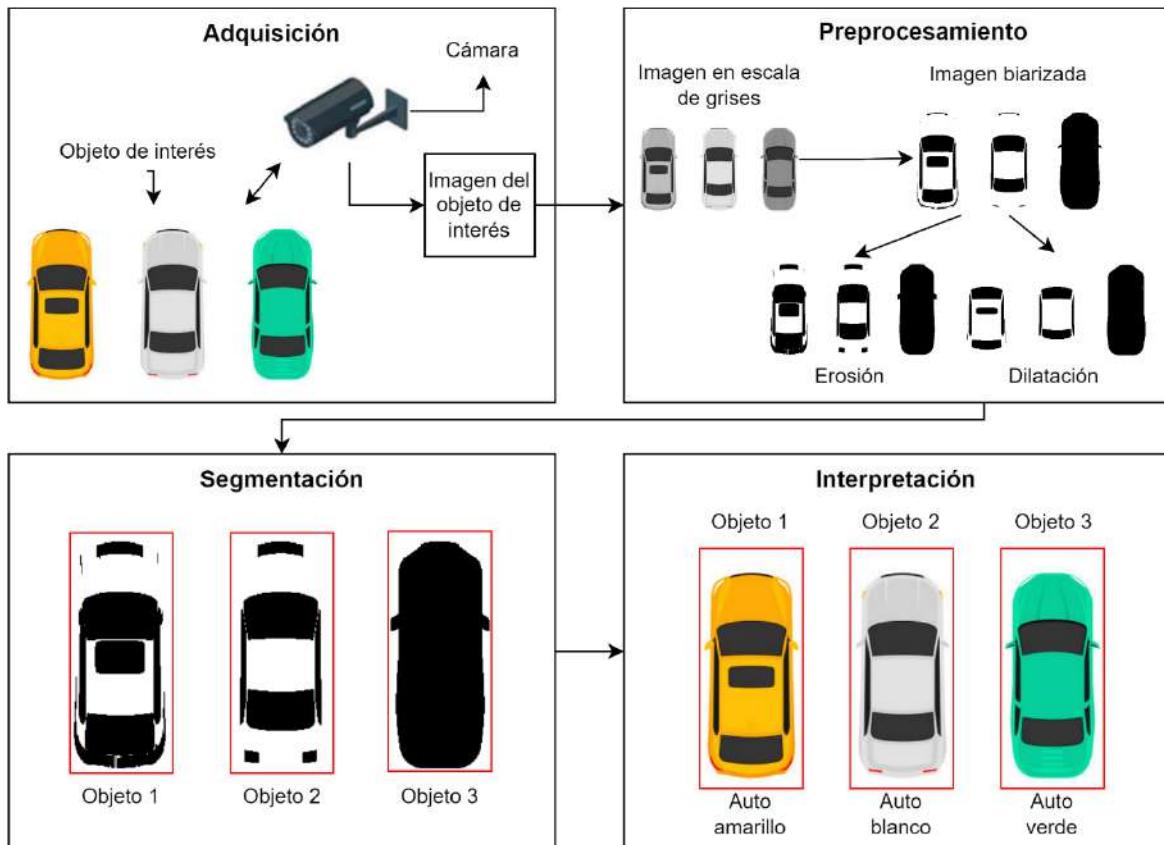


Figura 2.3 Etapas del proceso de visión artificial (autoría propia).

2.2.1. Formación y representación de la imagen

Es una representación visual de un objeto que ha sido extraído del medio ambiente. En las actividades visuales diarias, las imágenes que se perciben generalmente son el resultado de la luz reflejada por los objetos. La representación de una imagen se define como $f(x,y)^2$, y está compuesta por dos elementos principales: la iluminación, que es la cantidad de luz incidente proveniente de la fuente en la escena observada, y la reflectancia, que es la cantidad de luz reflejada por los objetos presentes en la escena. Las dos componentes que conforman la imagen se denominan iluminación, representada por $i(x,y)$, y reflectancia,

representada por $r(x, y)$. Estas dos funciones se combinan para generar la imagen final $f(x, y)$.

El proceso de generación de la imagen implica diferentes componentes, como el propio objeto, la fuente luminosa y el sistema de captura de imágenes. Este sistema está compuesto por un conjunto de elementos ópticos, un sensor y un dispositivo de digitalización. La imagen digital obtenida puede ser representada mediante una matriz f con dimensiones específicas de $N \times M$ como se muestra en la ecuación 2.2:

$$f = \begin{bmatrix} f(1,1) & f(1,2) & \cdots & f(1,M) \\ f(2,1) & f(2,2) & \cdots & f(2,M) \\ \vdots & \vdots & \ddots & \vdots \\ f(N,1) & f(N,2) & \cdots & f(N,M) \end{bmatrix} \quad (2.2)$$

2.2.2. Procesamiento de imágenes

Cualquier imagen adquirida mediante métodos ópticos, electroópticos o electrónicos es afectada por cierta degradación en forma de ruido, pérdida de definición e información. Esta degradación puede ser causada por la interferencia causada en los sensores de captura, desviaciones causadas en el ajuste del enfoque de la cámara, movimiento durante la captura o interferencias aleatorias, incluyendo el desplazamiento de la radiación a través del medio de transmisión. Las técnicas utilizadas para contrarrestar estos efectos forman parte del procesamiento de la imagen y se conocen como operaciones de restauración. El procesamiento de la imagen tiene como objetivo corregir los defectos presentes en la imagen que no fueron eliminados por el hardware, como deformaciones, ruido introducido, falta de contraste o brillo adecuados, y falta de ecualización adecuada, entre otros. Los algoritmos de procesamiento permiten modificar la imagen para quitar la interferencia, realizar transformaciones geométricas, mejorar la intensidad o el contraste (Azuela, 2013).

2.2.3. Umbralización

El proceso de umbralización, es conocido como thresholding, implica en establecer a 255 los valores por encima y en 0 los valores por debajo de un valor específico llamado umbral, que se define por la ecuación 2.3.

$$IMB(i,j) = IMA(i,j) * (IMA(i,j) \geq umbral) \quad (2.3)$$

Donde: *umbral* es un valor escalar que define el límite para la nueva matriz, *IMA(i,j)* es la matriz original, *IMB(i,j)* es una matriz de datos $N \times M$ que se forma a partir de eliminar los valores por encima o debajo de la matriz *IMA(i,j)*.

2.2.4. Binarización

Es una técnica derivada de la umbralización, que implica establecer un umbral y asignar el valor cero a todos los píxeles que sean menores que dicho umbral, mientras que los píxeles iguales o mayores al umbral se asignan al valor uno. De esta manera, la imagen final está compuesta de píxeles que son unos y ceros, formando una representación binaria, que se puede definir en la ecuación 2.4 y 2.5 (Laganiére, 2011).

$$\text{Si } IMA(x,y) \geq U, \text{ entonces } IMB(x,y) = 1 \quad (2.4)$$

$$\text{Si } IMA(x,y) \leq U, \text{ entonces } IMB(x,y) = 0 \quad (2.5)$$

Donde: *U* = valor del umbral, *IMB* = imagen binaria, *(x,y)* = posición de la imagen en alto y ancho.

2.2.5. Filtrado

Los filtros se aplican en dos dominios diferentes: el dominio espacial y el dominio frecuencial.

Las técnicas basadas en el primero implican el cambio directo de luz de los píxeles de la imagen. Se realizan operaciones directamente sobre los valores de los píxeles para un resultado deseado.

Por otro lado, los métodos basados en el segundo cambian indirectamente el contraste de cada píxel al utilizar los coeficientes de ponderación basados en los valores de otros píxeles de la imagen o de su entorno. Estos métodos se basan en las relaciones numéricas entre los píxeles y se aplican mediante transformadas, como la Transformada de Fourier, para realizar modificaciones en el dominio de las frecuencias de la imagen. Los cálculos espaciales se refieren al cambio directo del espectro de frecuencias de una imagen. El espectro de frecuencias espaciales de una imagen se puede calcular utilizando la ecuación 2.6. El proceso implica obtener el espectro tanto de la imagen como del filtro que se desea aplicar, y luego multiplicarlos para realizar el filtrado. Esto permite realizar modificaciones en la imagen al ajustar las componentes de frecuencia en el dominio espacial.

$$G(u, v) = F(u, v) * H(u, v) \quad (2.6)$$

Considerando $H(u, v)$ como la transformada de Fourier del filtro aplicado, y $F(u, v)$ y $G(u, v)$ como las transformadas de Fourier de la imagen original y la imagen filtrada respectivamente. Dado que las transformaciones en la imagen original, en el filtro y la transformada inversa pueden requerir un tiempo considerable de procesamiento, es necesario utilizar herramientas matemáticas que mejoren estos procesos (Maravall & Allende, 1993).

2.2.6. Segmentación

El proceso implica la subdivisión de la imagen en regiones separadas y distintas entre sí. El objetivo es diferenciar los objetos presentes en la imagen y su ubicación con respecto al fondo, que puede ser complejo. Este método tiene como finalidad obtener un conocimiento preciso de los objetos para poder obtener sus atributos individuales. Además, cada píxel de la imagen debe estar etiquetado de manera que se pueda obtener la lista de los elementos simplemente mediante la agrupación de puntos con la misma etiqueta y que estén conectados espacialmente.

2.2.7. Erosión binaria

Se tienen dos conjuntos A y B en el plano de Z^2 la erosión, simbolizada por $A \ominus B$, se define en la ecuación 2.7:

$$A \ominus B = \{x \in E^N \mid x = x + b \in A \text{ para todo } b \in B\} \quad (2.7)$$

A partir de una imagen A la erosión con respecto al elemento estructurante B implica que cada punto x tales que B , desplazado por x , existe en A . En la operación de erosión, se establece a nulo cada píxel de la imagen que no contienen en su totalidad al componente estructurante vecino. Esta operación tiene el efecto de reducir los contornos de los elementos que existen en la imagen. La erosión es usada especialmente para diferenciar objetos que están unidos por una mínima parte de sus contornos, permitiendo una segmentación más precisa y una separación más clara entre los objetos en la imagen.

2.2.8. Dilatación

Se tienen dos elementos A y B en el plano Z^2 la erosión, denotada por $A \oplus B$, se define como la ecuación 2.8:

$$A \oplus B = \{c \in E^N \mid c = a + b \text{ para todo } a \in A \text{ y } b \in B\} \quad (2.8)$$

Dada una ventana B (construida con unos y ceros), la dilatación de A en B es el conjunto

de todas las traslaciones de c tales que B y A se solapen en al menos un elemento diferente al valor nulo.

2.2.9. Segmentación basada en umbralización

Este método implica agrupar los píxeles en una imagen según los niveles de contraste. Cuando hay varios objetos con diferentes niveles de grises en la

imagen, se observarán múltiples picos en el histograma, correspondientes a cada objeto. El objetivo de la segmentación en este caso es encontrar un umbral que permita separar de manera efectiva los objetos del fondo.

Si las condiciones de iluminación y fondo son constantes y uniformes, es posible establecer el umbral de forma manual mediante prueba y error. Sin embargo, si la iluminación, el fondo y los objetos pueden variar, se requerirá desarrollar un sistema de cálculo automático del umbral.

El sistema automático de cálculo del umbral utiliza técnicas y algoritmos que analizan el histograma y buscan características específicas para determinar el umbral óptimo. Estas técnicas pueden considerar la forma del histograma, la distribución de los picos, la varianza entre los objetos y el fondo, entre otros factores. El objetivo es encontrar un umbral que maximice la separación entre los objetos y el fondo, de manera que se logre una segmentación precisa y robusta, incluso en condiciones variables de iluminación y fondo (Pajares-Cruz, 2007).

2.3. Machine Learning

Se centra en el desarrollo de algoritmos y modelos que permiten a las computadoras o sistemas aprender y tomar decisiones sin estar programadas. En lugar de escribir un conjunto de reglas específicas, el aprendizaje automático permite que los sistemas aprendan de los datos y mejoren su rendimiento a medida que se les proporciona más información. El desarrollo de algoritmos y modelos tiene un amplio campo de estudio en visión por computadora, procesamiento de señales eléctricas, diagnóstico médico, entre otros (Chollet, 2021).

2.3.1. Aumento de datos

Es una técnica comúnmente utilizada en machine learning para mejorar el rendimiento de los modelos, especialmente en casos donde el conjunto de datos es limitado o desbalanceado. La idea principal es generar nuevas muestras de datos a partir de las muestras existentes mediante la aplicación de transformaciones aleatorias o controladas.

Mediante técnicas basadas en la transformación de imágenes a los datos se le puede aplicar “espejo y rotación”, los cuales modifican la relación espacial de una imagen entre sus píxeles. En cuanto a “espejo” ($IMB(i,j)$), refleja o invierte una imagen ($IMA(i,j)$) usando la ecuación 2.9 (espejo vertical) y ecuación 2.10 (espejo horizontal) (González & Woods, 2017).

$$IMB(i,j) = IMA(N - i, j) \quad (2.9)$$

$$IMB(i,j) = IMA(i, M - j) \quad (2.10)$$

Donde: i, j = son las coordenadas de la imagen, N = es el ancho de la imagen, M = es la altura de la imagen.

En cuanto a “rotación”, dado un punto $IMB(i,j)$ se rota θ grados, las coordenadas i' y j' del nuevo punto resultan a partir de la ecuación 2.11.

$$\begin{bmatrix} i' \\ j' \end{bmatrix} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \cdot \begin{bmatrix} i \\ j \end{bmatrix} \quad (2.11)$$

De tal manera que la versión girada de la imagen principal será la mostrada en la ecuación 2.12.

$$IMB(i',j') = IMB(i \cdot \cos\theta - j \cdot \sin\theta, i \cdot \sin\theta + j \cdot \cos\theta) = IMA(i,j) \quad (2.12)$$

Donde: θ es el ángulo de rotación que se le aplicará a la imagen.

De igual forma se aplica ajuste de contraste, el cual implica expandir o contraer el rango de intensidades de los píxeles para aumentar o disminuir la diferencia entre las intensidades más claras y oscuras (Cuevas et al., 2017).

Una de las fórmulas más comunes para ajustar el contraste es la ecuación 2.13.

$$AjustedeContraste(x,y) = m * Original(x,y) + c \quad (2.13)$$

Donde: $AjustedeContraste(x,y)$ es el valor de píxel ajustado en la imagen con contraste, $Original(x,y)$ es el valor de píxel original en la imagen, m es la pendiente de la línea de transformación, que controla el factor de aumento o disminución del contraste y c es el constante de desplazamiento, que controla el brillo de la imagen.

2.3.2. Aprendizaje no supervisado

Se enfoca en encontrar patrones, estructuras o relaciones ocultas en conjuntos de datos sin etiquetar, a partir de las entradas de datos el resultado es obtener una estructura debajo del objetivo final. Para identificar los grupos en ocasiones se disminuye la dimensión de este, para representarlos en un espacio menor, el algoritmo asigna instancias de valores similares y busca maximizar la similitud dentro de cada grupo (Bishop, 2006).

2.3.3. Aprendizaje supervisado Análisis Discriminante Lineal

El análisis discriminante lineal (por sus siglas en inglés LDA) es una técnica estadística utilizada para encontrar una combinación lineal de variables que distingue o separa dos o más grupos imágenes (Duda et al., 2012). Es útil cuando tienes un conjunto de datos con variables predictoras de modo que se pueda determinar si es posible distinguir entre diferentes grupos en base a esas variables (Figura 2.4).

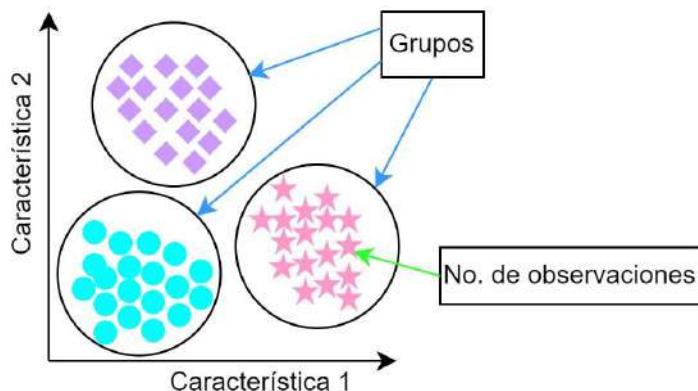


Figura 2.4 Separación de clases (Autoría propia).

Para que la técnica LDA pueda separar las clases se deben identificar características que puedan describir las imágenes de cada clase, para esta investigación se utilizaron las mencionadas en la tabla 2.4, donde se describe que característica es, su respectiva ecuación y descripción.

Tabla 2.1 Características en imágenes RSW (Zhang & Senkara, 2017).

| Característica | Ecuación | Descripción |
|----------------------|--|--|
| Valor máximo | $f = \max(x)$ | Indica la presencia de zonas muy brillantes, identifica características |
| Valor mínimo | $f = \min(x)$ | Identifica áreas oscuras, de esta manera identificar zonas con defectos |
| Promedio | $f = (\frac{\sum_{x=1}^m \sum_{y=1}^n G(x, y)}{m * n})$ | Uniformidad de la soldadura |
| Intensidad media | $fm = \frac{1}{n} * \sum_{k=1}^n (x_k - \bar{x})^2$ | Mide el brillo promedio del área de la soldadura, lo que puede indicar uniformidad en la distribución de calor. |
| Desviación estándar | $f = \sqrt{\frac{\sum_{x=1}^m \sum_{y=1}^n [I(x, y) - \mu]^2}{m * n}}$ | Cuantifica la variación en el brillo dentro de la soldadura, ayuda a detectar irregularidades |
| Asimetría (Skewness) | $f = \frac{\sum_{x=1}^m \sum_{y=1}^n [I(x, y) - \mu]^3}{m * n * \sigma^2}$ | Evalúa la falta de simetría en la distribución de intensidad en la soldadura. Una distribución asimétrica puede indicar un calentamiento no uniforme |
| Curtosis | $f = \frac{\sum_{x=1}^m \sum_{y=1}^n [I(x, y) - \mu]^4}{m * n * \sigma^4}$ | Caracterizar la distribución de los niveles de intensidad de los píxeles en la imagen |
| Energía | $f = \frac{\sum_{x=1}^m \sum_{y=1}^n I(x, y)^2}{m * n}$ | Proporciona la intensidad de la imagen, regiones donde existe el calor de los electrodos con mayor fuerza |
| Entropía | $f = \frac{\sum_{x=1}^m \sum_{y=1}^n I(x, y) * [-\log I(x, y)]}{m * n}$ | Cuantifica la aleatoriedad o desorden en los valores de intensidad. Una entropía alta puede indicar una calidad de soldadura inconsistente |
| Tercer momento | $ft = \frac{1}{k(\sqrt{fm^2})} \sum_{k=1}^k (s(k) - g)^3$ | Cuantifican información sobre la forma y la distribución de los valores de la intensidad |
| Cuarto momento | $fc = \frac{1}{k(\sqrt{fm^2})} \sum_{k=1}^k (s(k) - g)^4$ | Cuantifican información sobre la forma y la distribución de los valores de la intensidad |

Donde: n , k es el número de datos, σ es la desviación estándar, x es el vector de datos, \bar{x} es la media de datos, μ es el momento ordinario de orden 1, $s(k)$ son los valores individuales de la muestra y g es la media de la muestra.

Una vez seleccionadas las características estadísticas para aplicar el LDA se siguieron 5 pasos para la aplicación correcta los cuales se enumeran a continuación.

1. Obtener las medias de cada vector d-dimensional para cada clase.
2. Obtener las matrices de dispersión entre clases (SB) y la matriz de dispersión dentro de las clases (SW).

Matriz de dispersión entre clases (SB): esta matriz representa la dispersión entre las clases en un conjunto de datos. Es un valor que indica la separación de las clases entre sí en el espacio de características. La matriz SB se calcula con la ecuación 2.14.

$$SB = \sum_{i=0}^c N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.14)$$

Donde: c es el número de clases, N_i es el número de muestras en la clase i , μ_i es el vector de medias de la clase i , μ es el vector de medias de todas las muestras, y T denota la transpuesta.

Matriz de dispersión dentro de las clases (SW): esta matriz representa la dispersión dentro de las clases en un conjunto de datos. Es una medida de cómo están agrupadas las muestras dentro de cada clase. La matriz SW se calcula con la ecuación 2.15.

$$SW = \sum_{i=1}^c \sum_{j=0}^{N_i} (x_{ij} - \mu_i)(x_{ij} - \mu_i)^T \quad (2.15)$$

Donde: c es el número de clases, x_{ij} es la j -ésima muestra de la clase i , μ_i es el vector de medias de la clase i , N_i es el número de muestras en la clase i y T denota la transpuesta.

3. Obtener los eigenvalores y eigenvectores para las matrices de dispersión con la ecuación 2.16.

$$S_w^{-1} S_b = \lambda w \quad (2.16)$$

4. Ordenar de forma descendente y elegir la dimensión k del nuevo espacio reducido con la ecuación 2.17.

$$W = Kxd \quad (2.17)$$

5. Usar el vector W para transformar el espacio original X en el nuevo espacio con la siguiente ecuación 2.18.

$$Y = XxW \quad (2.18)$$

Esta técnica se utiliza para maximizar la separación entre clases (minimizando SW) mientras mantiene las clases lo más compactas posible (maximizando SB) (Duda et al., 2001).

2.4. Redes neuronales convolucionales

Las redes neuronales son una herramienta muy valiosa en el campo de la inspección visual, y se utilizan ampliamente en aplicaciones como: clasificación de imágenes, reconocimiento de objetos, el reconocimiento facial y la segmentación de imágenes. Las redes neuronales convolucionales (CNN) se utilizan comúnmente en los sistemas de visión artificial. Las CNN (Figura 2.6) están diseñadas para detectar características jerárquicas en las imágenes a través de múltiples capas de convolución, capas de reducción máxima y capas conectadas.

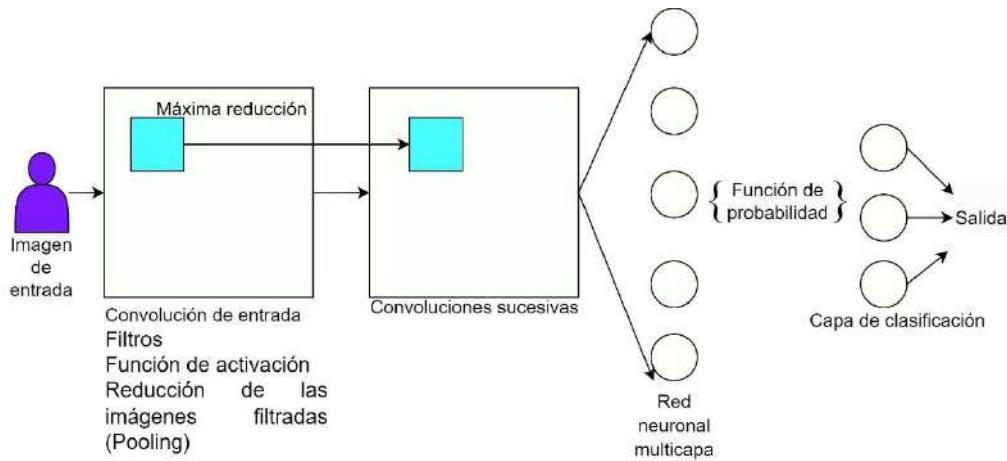


Figura 2.5 Red neuronal convolucional (Autoría propia).

La capa de convolución se encarga de extraer características locales de la imagen, como bordes y texturas. La operación de convolución se realiza entre una entrada (generalmente una imagen) y un conjunto de filtros (o kernels). La salida de una capa convolucional es una nueva imagen o un conjunto de mapas de características. La ecuación 2.19 para un mapa de características y_{ij} generado por un filtro W aplicado a una entrada x es:

$$y_{ij} = (x * W)_{ij} + b \quad (2.19)$$

Después de aplicar la convolución, se pasa el resultado a través de una función de activación comúnmente la ReLU (por sus siglas en inglés Rectified Unit Linear) que se define por la ecuación 2.20.

$$\text{ReLU}(z) = \max(0, z) \quad (2.20)$$

Donde: z es el valor del mapa de características después de la convolución y la adición del sesgo.

La capa de pooling reduce la dimensión de la imagen al muestrear y fusionar las características aprendidas en la capa de convolución, generalmente con operaciones de max-pooling o average-pooling (ecuación 2.21).

$$y_{ij} = \max(x_{m,n}: m, n \in ventana) \quad (2.21)$$

Donde: *ventana* es un subconjunto de la entrada x alrededor de la posición (i, j) , y_{ij} es el valor de la resultante del pooling en la posición (i, j) .

Finalmente, la capa conectada utiliza las características aprendidas para realizar tareas de clasificación o detección, definida por la ecuación 2.22.

$$y = Wx + b \quad (2.22)$$

Las CNN se entranan minimizando una función de pérdida, que mide la discrepancia entre las predicciones de la red y las etiquetas verdaderas. Una de las funciones de pérdida más comunes es la entropía cruzada para clasificación es la ecuación 2.23.

$$L(y, \hat{y}) = - \sum_i y_i \log (\hat{y}_i) \quad (2.23)$$

Donde: y es el vector de las etiquetas verdaderas, \hat{y}_i es el vector de las predicciones de la red.

Una de las herramientas para identificar la precisión de entrenamiento de una CNN es la matriz de confusión la cual es utilizada en la evaluación del rendimiento de un modelo de clasificación. Proporciona una representación visual de las predicciones del modelo en comparación con los valores reales. La matriz de confusión tiene la siguiente forma (Figura 2.6):

| | | Valores actuales | |
|-------------------|----------|------------------|----------|
| | | Negativo | Positivo |
| Valores predichos | Negativo | TN | FN |
| | Positivo | FP | TP |

Figura 2.6 Matriz de confusión (Autoría propia).

Donde: TN (Verdaderos negativos) es el número de casos correctamente predichos como negativos, FN (Falsos Negativos) es la cantidad de casos incorrectamente predichos como negativos (fallos en la detección), FP (Falsos positivos) es el número de casos incorrectamente predichos como negativos (fallos en la detección) y TP (Verdaderos positivos) es la cantidad de casos correctamente predichos como positivos. A partir de la matriz de confusión, se pueden calcular varias métricas para evaluar el rendimiento del modelo (Goodfellow et al., 2016).

Precisión: La precisión mide la proporción de predicciones correctas (tanto positivas como negativas) respecto al total de predicciones (ecuación 2.24).

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.24)$$

Precisión de predicciones positivas: La precisión mide la proporción de verdaderos positivos respecto al total de predicciones positivas (ecuación 2.25).

$$P = \frac{TP}{TP + FP} \quad (2.25)$$

Sensibilidad (Recall): La sensibilidad mide la proporción de verdaderos positivos respecto al total de casos positivos reales (ecuación 2.26).

$$Recall = \frac{TP}{TP + FN} \quad (2.26)$$

Especificidad: La especificidad mide la proporción de verdaderos negativos respecto al total de casos negativos reales (ecuación 2.27).

$$S = \frac{TN}{TN + FP} \quad (2.27)$$

Valor F1 (F1 Score): El valor F1 es la media armónica de la precisión y la sensibilidad, proporcionando un equilibrio entre las dos métricas (ecuación 2.28).

$$F1 = \frac{2 * A * Recall}{A + Recall} \quad (2.28)$$

Una de las principales ventajas de las CNN es la capacidad para reconocer automáticamente características útiles a partir de los datos, lo que reduce significativamente la identificación de características de forma manual. Además, las CNN son capaces de manejar imágenes de alta resolución y datos en tiempo real.

Las redes neuronales se utilizan para detectar y segmentar objetos en imágenes y videos. La detección de objetos también se puede realizar utilizando redes neuronales de detección de objetos (ODN) que utilizan una única red para realizar la detección y la clasificación simultáneamente (Torres, 2020).

2.5. Software de código libre

2.5.1. Python

Python es un lenguaje de programación de alto nivel. Fue creado por Guido van Rossum y lanzado por primera vez en 1991. Python se destaca por su sintaxis clara y legible, lo cual lo hace muy amigable para principiantes. Es un lenguaje

versátil que se utiliza ampliamente en diferentes áreas, como desarrollo web, análisis de datos, inteligencia artificial, automatización de tareas, entre otros. Algunas características distintivas de Python son:

- Sintaxis sencilla: Python utiliza una sintaxis limpia y legible, lo que facilita la comprensión y el mantenimiento del código.
- Tipado dinámico: No es necesario declarar explícitamente los tipos de variables, ya que Python realiza la inferencia de tipos de manera automática.
- Amplia biblioteca estándar: Python cuenta con una amplia biblioteca estándar que proporciona módulos y funciones para realizar una amplia gama de tareas, desde operaciones básicas hasta tareas avanzadas.
- Orientación a objetos: Python soporta la programación orientada a objetos, lo que permite la creación de clases y objetos para organizar y estructurar el código (Laganiére, 2011).

3. METODOLOGÍA

La Figura 3.1 muestra la metodología que se utilizó para clasificar los errores de soldadura del tipo rebaba, esta desglosada en 6 etapas. En la etapa uno se generó una muestra de una base de datos en imágenes con defectos de soldadura del tipo rebaba. Posteriormente, en la etapa dos se identificaron las clases de defectos a partir de las características de cada imagen, que servirán para diferenciar los puntos correctos de las otras clases. En la etapa tres se realizó un aumento de datos a partir de transformaciones geométricas (espejo y rotación), con la finalidad de obtener una base de datos equilibrada por tener pocas imágenes originales. En la etapa 4, se utilizó el método de reconocimiento de patrones supervisado LDA de modo que se puedan distinguir las clases de defectos RSW. Posteriormente, en la etapa 5 se obtuvo el modelo de aprendizaje automático basado en la validación cruzada. Finalmente, en la etapa 6 se implementó la metodología en una interfaz gráfica de usuario con el propósito de validar y testear el rendimiento de esta.

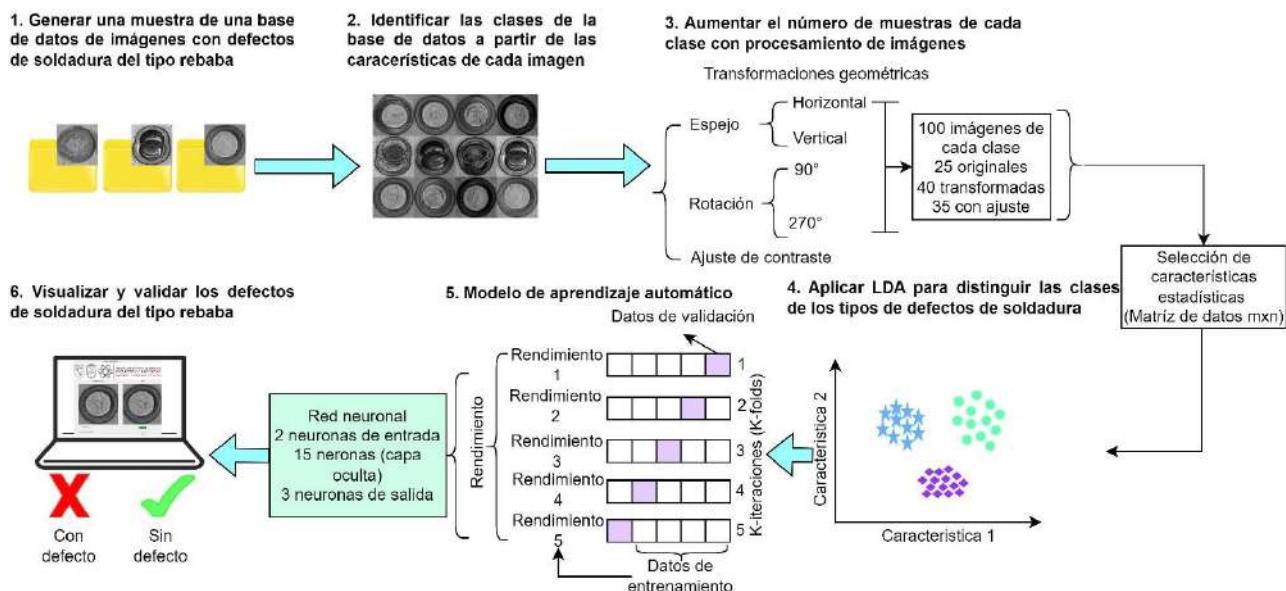


Figura 3.1 Metodología (autoría propia).

A continuación, se desglosan los puntos de la metodología propuesta.

3.1. Base de datos

Dado que no existe una base de datos con imágenes de RSW que este previamente etiquetada y distribuida en clases, se generó una muestra de una base de datos de imágenes con defectos RSW, que contengan errores de soldadura del tipo rebaba, a partir de una base de datos de imágenes publicadas por Dai et al. (2022). De estas imágenes se obtienen los puntos de soldadura (Figura 3.2).



Figura 3.2 Imágenes RSW Dai et al. (2022).

Para obtener los recortes de las imágenes RSW de la Figura 3.2 se realizó el proceso mencionado en la Tabla 3.1.

Tabla 3.1 Proceso para obtener una imagen RSW

| Pasos | Descripción | Ecuación |
|---------------------------------------|---|---|
| 1. Imagen seleccionada | Se selecciono una imagen RSW a color | $IMA(i)$ Donde: IMA = imagen, i = número de imagen |
| 2. Escala de grises | La imagen seleccionada se convierte en una imagen en blanco y negro con valores entre el rango de 0 a 255 | $G = 0.2989xR + 0.5870 * G + 0.1140 * B$ Donde: G = Imagen en escala de grises, R = Canal de color rojo, G = Canal de color verde, B = Canal de color azul |
| 3. Umbralización y binarización | Con el método de umbralización se selecciona el valor óptimo para binarizar la imagen y dejarlo en valores de 0 y 1 | Si $G(x,y) \geq U$, entonces $B(x,y) = 1$ Si $G(x,y) \leq U$, entonces $B(x,y) = 0$ Donde: U = valor de umbral, B = imagen binaria, (x,y) = posición de la imagen en alto y ancho |
| 4. Recorte de ROI (Región de interés) | A partir de la imagen obtenida con valores entre 0 y 1, se selecciona la región e interés y se realiza el recorte de la imagen RSW en 64x64 pixeles | $R = B(y1:y2,x1;x2)$ Donde R = Recorte de la imagen RSW, $(y1:y2,x1;x2)$ = rango de valores en alto y ancho de la imagen binaria |

3.2. Identificación de clases de defectos RSW

Las imágenes seleccionadas tienen un tamaño de 64x64 pixeles, se elige este tamaño de imagen porque es suficiente para capturar las características de cada imagen, los modelos de entrenamiento y validación utilizan un menor tiempo en procesar cada imagen, por último, la unidad de procesamiento gráfico trabaja eficientemente por la cantidad de datos que se están analizando, de acuerdo con las características de cada imagen se identificaron 3 clases como se muestra en la Figura 3.3.

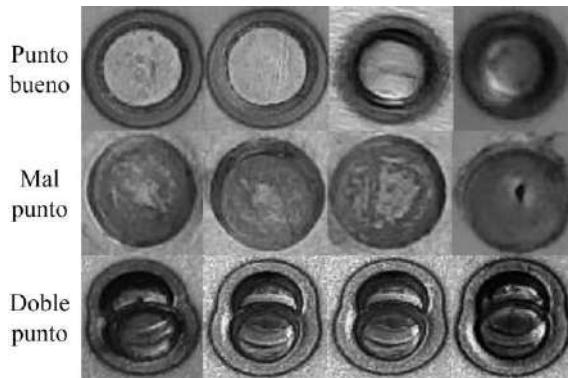


Figura 3.3 ROI imágenes RSW Dai et al. (2022).

Un “punto bueno” de soldadura significa que en el círculo interior presenta uniformidad, no existe una rebaba y en la parte externa se muestra el relieve que determina que existió una buena conductividad eléctrica en los electrodos, una presión adecuada y un buen control de tiempo-temperatura. Un “mal punto” presenta una circunferencia no uniforme, la corriente eléctrica y la presión en los electrodos no es la adecuada, lo cual puede presentar una soldadura fría (unión inadecuada entre piezas), en la unión pueden existir deformaciones de material o fractura permanente. Por último, el “doble punto” se refiere a que dos puntos se superponen entre sí, puede producirse una falta de fusión; en caso de que la corriente eléctrica o la presión aplicada no sean uniformes para ambos puntos, un mal control en la aplicación puede provocar deformaciones no deseadas en la pieza, lo que afectaría su geometría, precisión y calidad estética (Boriwal et al., 2017).

A partir de las imágenes que fueron seleccionadas con el proceso mencionado de la Tabla 3.1, se desea obtener la siguiente distribución de cada clase (Tabla 3.2).

Tabla 3.2 Distribución de clases base de datos

| Clase | Imágenes |
|-------------|----------|
| Punto bueno | 25 |
| Punto malo | 25 |
| Doble punto | 25 |

3.3. Aumento de datos a partir del procesamiento de imágenes

Utilizando técnicas basadas en la transformación de imágenes a los datos se le puede aplicar “espejo, rotación y ajuste de contraste”, los cuales modifican la relación espacial de una imagen entre sus pixeles.

Al aplicar estas funciones a las imágenes originales de cada clase se desea obtener la distribución de la Tabla 3.3.

Tabla 3.3 Base de datos aumentada

| Clase | Original | Espejo | Rotación | Ajuste de contraste | Ajuste de contraste | Total |
|-------------|----------|--------|----------|------------------------|------------------------|-------|
| Punto bueno | 25 | 20 | 20 | 17 | 18 | 100 |
| Punto malo | 25 | 20 | 20 | 17 | 18 | 100 |
| Doble punto | 25 | 20 | 20 | 17 | 18 | 100 |

3.4. Aplicar LDA para distinguir las clases de los tipos de defectos de soldadura

Mediante la técnica supervisada de Machine Learning LDA el cual es una técnica de aprendizaje supervisado utilizada en estadísticas y reconocimiento de patrones. Su objetivo es encontrar la combinación lineal de características que mejor discriminan entre dos o más clases. En el contexto de la clasificación de imágenes, se puede aplicar LDA para reducir la dimensionalidad de los datos y

mejorar la separación entre las clases. Se utiliza porque reduce considerablemente el tiempo de procesar una imagen al obtener características específicas y de esta manera mejorar el tiempo de procesamiento de los modelos de aprendizaje de clasificación.

El proceso para llevar a cabo la separación de dos o más grupos del LDA es el siguiente (Figura 3.4):

- 1) Recopilación de datos: Se recopilan imágenes de muestras pertenecientes a diferentes grupos o clases.
- 2) Selección de variables predictoras: Se eligen las variables predictoras que se utilizarán para clasificar las observaciones en grupos.
- 3) Cálculo de las funciones discriminantes: Se calculan las funciones discriminantes lineales, que son combinaciones lineales de las variables predictoras que maximizan la separación entre los grupos.
- 4) Clasificación: Se utiliza la función discriminante para clasificar nuevas observaciones en los grupos predefinidos.

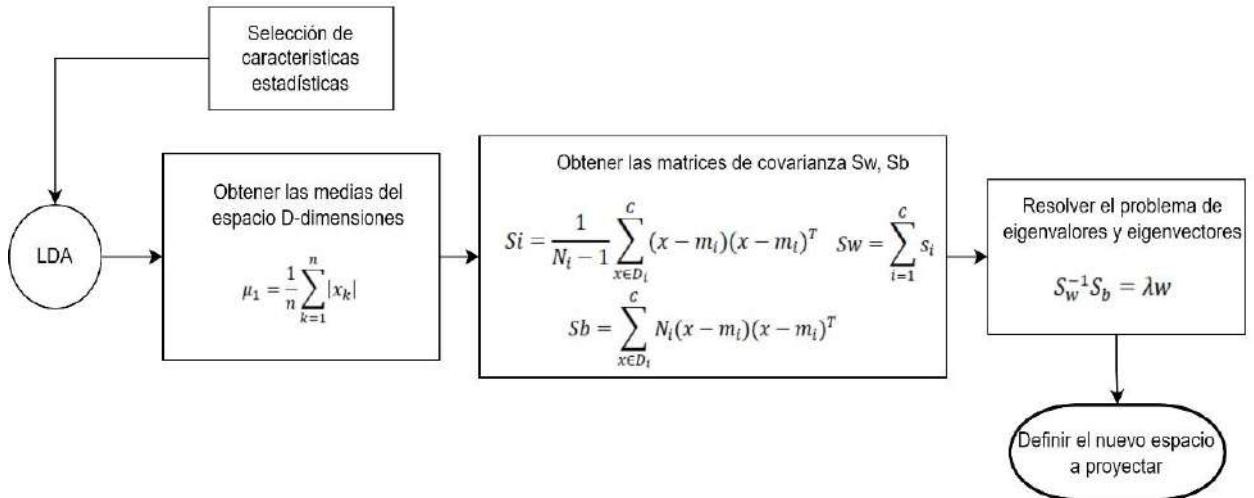


Figura 3.4 Proceso LDA (Autoría propia).

Las características estadísticas seleccionadas para obtener la información de cada imagen se muestran en la Tabla 2.4, los cuales son las recomendadas para describir las imágenes RSW.

3.5. Modelo de aprendizaje automático

En esta etapa se tomará como entrada los resultados obtenidos de la selección de características y aplicar la técnica LDA a los datos obtenidos de la selección de características. Estos datos se seleccionan para obtener un clasificador que permitirá diagnosticar el defecto la imagen RSW. Para ello se propuso utilizar una técnica de clasificación con la configuración K-fold y red neuronal.

El proceso de k-fold es una técnica comúnmente utilizada en la evaluación de modelos de aprendizaje automático. A continuación, se mencionan los pasos principales a seguir para obtener el modelo.

1. División del conjunto de datos: Primero, se divide el conjunto de datos en k subconjuntos aproximadamente iguales. Estos subconjuntos pueden llamarse "particiones".
2. Selección de una partición como conjunto de validación: Se selecciona uno de los k pliegues como conjunto de validación y los otros $k - 1$ particiones se utilizan como conjunto de entrenamiento.
3. Entrenamiento del modelo: El modelo se entrena utilizando el conjunto de entrenamiento que se seleccionó en el paso anterior.
4. Evaluación del modelo: El modelo entrenado se evalúa utilizando el conjunto de validación que se seleccionó en el paso anterior. Se calcula una métrica de rendimiento, como precisión, exactitud, MSE (error cuadrático medio), etc.

El proceso para obtener la red neuronal se menciona a continuación.

1. Diseñar la arquitectura de la red neuronal: se elige la configuración de la red neuronal, incluyendo el número de capas, el número de neuronas en

- cada capa, las funciones de activación, etc. Esto puede requerir experimentación y ajuste.
2. Inicializar la red neuronal: utilizar un software apto de redes neuronales para inicializar la arquitectura de la red neuronal.
 3. Compilar el modelo: configurar el proceso de entrenamiento de la red neuronal, especificando el algoritmo de optimización, la función de pérdida y las métricas que se utilizarán para evaluar el rendimiento del modelo.
 4. Entrenar la red neuronal: entrena la red neuronal utilizando el conjunto de datos de entrenamiento. Ajustar los hiperparámetros según sea necesario utilizando el conjunto de validación.
 5. Evaluar el modelo: una vez que el modelo esté entrenado, evaluar su rendimiento utilizando el conjunto de prueba. Calcula métricas de rendimiento relevantes, como precisión o exactitud.

3.6. Visualización y validación del error de soldadura del tipo rebaba

Se desarrollará una interfaz gráfica (GUI) en software de código libre (inicialmente se propondrá utilizar Python) que permitirá visualizar la clasificación del error de soldadura del tipo rebaba. Para ello, se ingresará una imagen y devolverá la imagen etiquetada, se mostrará el diagnóstico, es decir, si presenta algún error del tipo rebaba o en su defecto, si no existe ningún error. Por último, se validarán la eficiencia del algoritmo de reconocimiento de patrones y el clasificador automático, como se muestra en la Figura 3.5.



Figura 3.5 Interfaz de usuario (Autoría propia).

4.RESULTADOS

A continuación, se presentan los resultados obtenidos de la metodología obtenida para la clasificación de defectos en imágenes de soldadura por punto por resistencia eléctrica, lo cual fueron 6 pasos. Inicialmente se generó una base de datos a partir de un conjunto de imágenes RSW, después se identifican las clases a partir de las similitudes entre imágenes identificando los defectos de las imágenes RSW. A continuación, se aumenta el número de datos utilizando transformación geométrica y ajuste de intensidad, este aumento de datos se realiza para obtener un mayor número de muestras de lo contrario al aplicar la técnica LDA las matrices entre clases y dentro de las clases tienen sobreajuste y generan valores nulos. El siguiente paso consistió en aplicar la técnica LDA para obtener una separación gráfica de las clases del conjunto de datos. El 5to paso se basó en obtener un modelo de entrenamiento utilizando K-fold y una red neuronal. Finalmente se desarrolló una GUI en el software Python para validar la metodología obtenida, en la Tabla 4.1 se muestra una matriz de pruebas que será base para validar la metodología aplicada en la GUI, el resultado esperado en los algoritmos obtenidos es el 96.0%, mientras que las pruebas de las imágenes RSW sean clasificadas correctamente en la clase correspondiente, por último se obtendrá un porcentaje de eficiencia de la interfaz GUI a partir de la correcta clasificación de cada imagen RSW.

Tabla 4.1 Matriz de pruebas

| Identificador | Nombre | Datos de entrada | Resultado esperado |
|---------------|--|----------------------------|--------------------|
| A1 | Algoritmo de entrenamiento | Imágenes de entrenamiento | 96.0% |
| A2 | Algoritmo de testeo | Imágenes de prueba | 96.0% |
| P1 | Prueba 1 imagen clase punto bueno | Imagen original | Clase punto bueno |
| P2 | Prueba 2 imagen clase punto malo | Imagen original | Clase punto malo |
| P3 | Prueba 3 imagen clase doble punto | Imagen original | Clase doble punto |
| P4 | Prueba 4 imagen transformada clase punto bueno | Imagen transformada | Clase punto bueno |
| P5 | Prueba 5 imagen transformada clase punto malo | Imagen transformada | Clase punto malo |
| P6 | Prueba 6 imagen transformada clase doble punto | Imagen transformada | Clase doble punto |
| I1 | Interfaz gráfica de usuario | Clasificación de la imagen | 99.0% |

4.1. Base de datos

El proceso para obtener la base de datos se menciona en la Tabla 3.1, el cual consiste en los pasos que se muestra en la Figura 4.1, 4.2 y 4.3. Al aplicar el proceso mencionado se obtuvo los recortes de los puntos de las imágenes RSW.

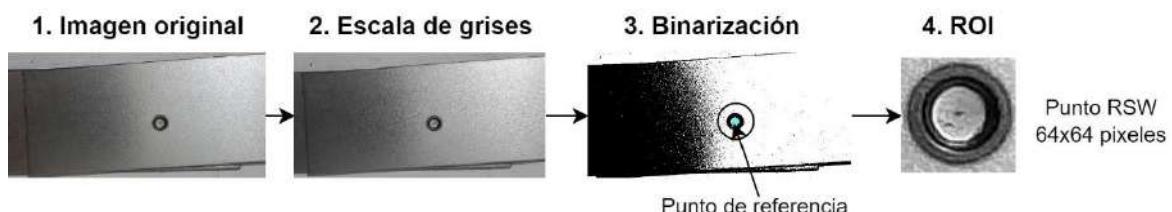


Figura 4.1 Proceso para obtener una imagen RSW punto bueno (autoría propia).

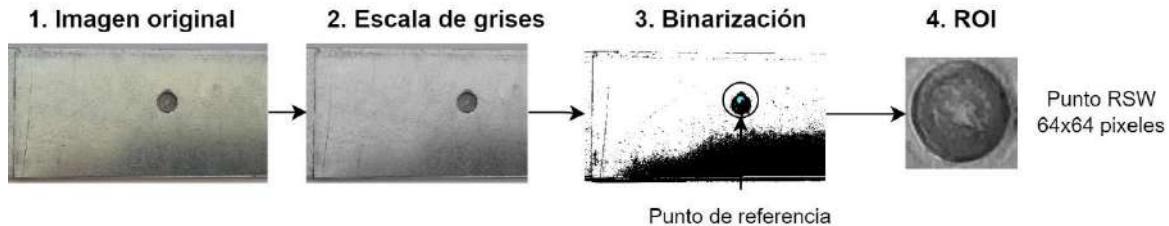


Figura 4.2 Proceso para obtener una imagen RSW punto malo (autoría propia).

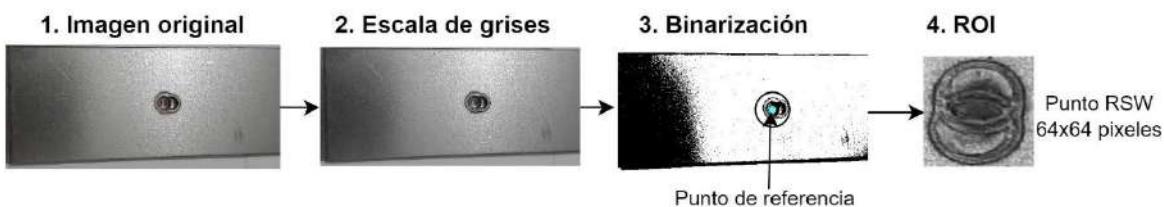


Figura 4.3 Proceso para obtener una imagen RSW doble punto (autoría propia).

Al observar cada imagen recortada se puede visualizar las diferencias entre cada clase, respecto a la imagen obtenida del punto bueno se muestra con uniformidad en la unión de las placas soldadas, de igual forma muestra una circunferencia continua y la rebaba no se presenta en la parte interna de la circunferencia. En la imagen del punto malo la circunferencia es discontinua, se puede presentar rebaba en la parte interna del punto y en ocasiones presentar fractura o penetración en las chapas soldadas. Finalmente, en la imagen de doble punto muestra dos puntos superpuestos, el cual puede presentar rebaba en las uniones y a pesar de ser generar mayor fuerza de unión entre las chapas soldadas no es tan recomendable aplicar este tipo de puntos por la calidad y estética que presenta.

4.2. Identificación de clases RSW

Para identificar las clases y agrupar las imágenes se hizo de forma visual por las características físcas de cada imagen, sin embargo para tener precisión en el etiquetado de clases se utilizó el umbral óptimo para cada clase mostrado en la

Tabla 4.2, donde se puede observar que las clases punto bueno y doble punto su umbral es un rango de valores, sin embargo, para punto malo el umbral es constante, con estas características de umbral óptimo se agrupan y etiquetan las imágenes en las tres clases mostradas en las Figuras 4.1 a 4.3 obteniendo la distribución de la Tabla 4.3, el cual muestra una distribución equilibrada al obtener 25 imágenes de cada clase.

Tabla 4.2 Umbral óptimo de las clases de imágenes RSW

| Clase | Umbral |
|-------------|---------------|
| Punto bueno | 0.4471-0.4627 |
| Punto malo | 0.5333 |
| Doble punto | 0.4314-0.4392 |

Tabla 4.3 Base de datos original

| Clase | Imágenes |
|-------------|----------|
| Punto bueno | 25 |
| Punto malo | 25 |
| Doble punto | 25 |

4.3. Aumento de datos a partir de transformaciones geométricas y ajuste de intensidad

En el apartado 3.3 se mencionan las ecuaciones que se utilizaron para realizar el aumento de datos, de las imágenes originales se realizan 2 transformaciones geométricas y dos ajustes de intensidad, en la función espejo se utilizó la transformación vertical, en cuanto a rotación se hizo a 90° , finalmente el ajuste de intensidad, fueron valores de contraste de 0.1 a 0.7 y 0.2 a 0.9, de esta forma se obtuvo la base de datos base (Tabla 4.4) para clasificar los defectos de imágenes RSW.

Tabla 4.4 Base de datos aumentada

| Clase | Original | Espejo | Rotación | Ajuste de contraste (0.1-0.7) | Ajuste de contraste (0.2-0.9) | Total |
|-------------|----------|--------|----------|-------------------------------|-------------------------------|-------|
| Punto bueno | 25 | 20 | 20 | 17 | 18 | 100 |
| Punto malo | 25 | 20 | 20 | 17 | 18 | 100 |
| Doble punto | 25 | 20 | 20 | 17 | 18 | 100 |

Para observar la modificación entre pixeles en las funciones utilizadas se muestra la Figura 4.4, el cual muestra la imagen original y las imágenes transformadas con su respectiva función, como se puede observar la disposición de los pixeles cambia, esto se realizó para aumentar la variabilidad de los datos en las características de cada imagen.

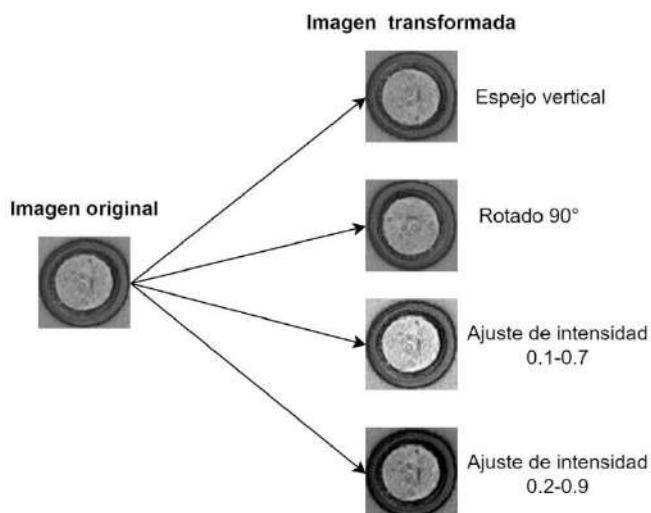


Figura 4.4 Imagen transformada (Autoría propia).

4.4. Separación de clases con la técnica LDA

Antes de aplicar la técnica de separación de clases LDA se realizó un ventaneo a las imágenes RSW con la finalidad de obtener el mayor número de características que describen mejor a la imagen, inicialmente se eligió un ventaneo

de 8x8 pixeles, sin embargo este ventaneo provocaba un sobreajuste al aplicar el LDA, después se optó por un ventaneo de 16x16 pixeles el cual redujo el número de características de la imagen y evitó el sobreajuste, por último el ventano de 32x32 pixeles ya no se realizó porque el resultado se parecía a la imagen original y la descripción de características sería similar a la misma. En la Figura 4.5 se muestra el proceso del venteo de 16x16 pixeles obteniendo 16 segmentos de la imagen original, este ventaneo se realizó con un algoritmo automático.

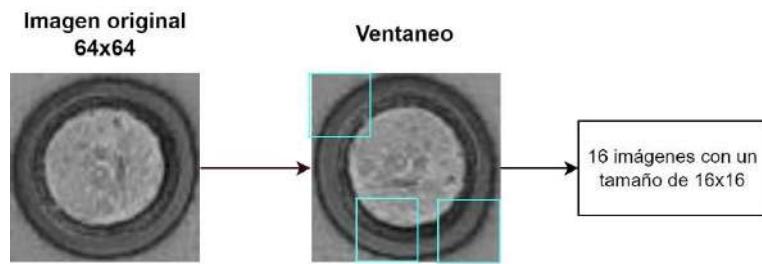


Figura 4.5 Ventaneo de imagen (Autoría propia).

Las características que representan un cambio respecto a las clases “punto bueno, punto malo, doble punto” son tres: valor rms, entropía y curtosis (Figura 4.6, Figura 4.7, Figura 4.8, respectivamente), sin embargo, las otras 4 características obtenidas no muestran un cambio significativo, de esta manera se decide utilizar LDA el cual separa las clases en dos otras dimensiones dependiendo de la separación de clases. Curtosis es la línea de color verde, valor rms y entropía son las mostradas en color azul y rojo.

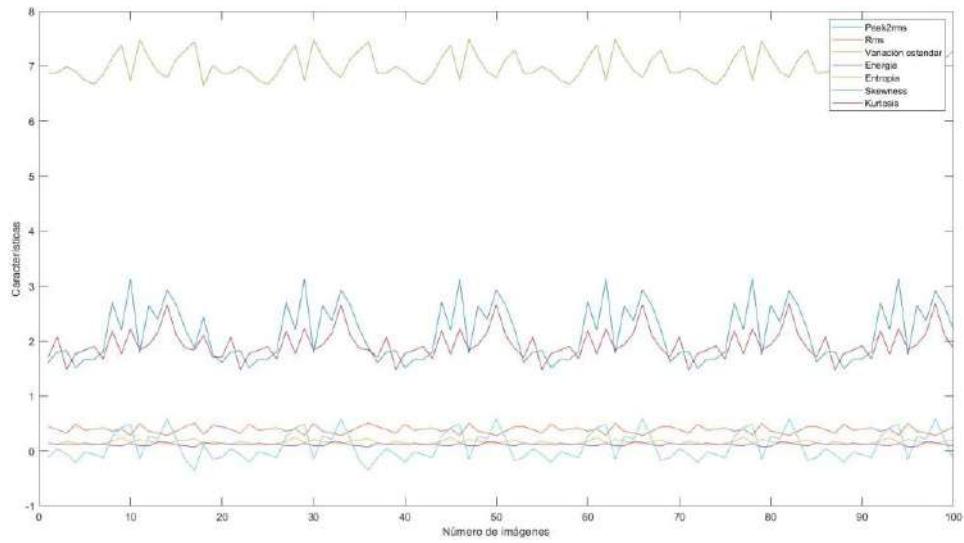


Figura 4.6 Características que describen la clase RSW punto bueno (Autoría propia).

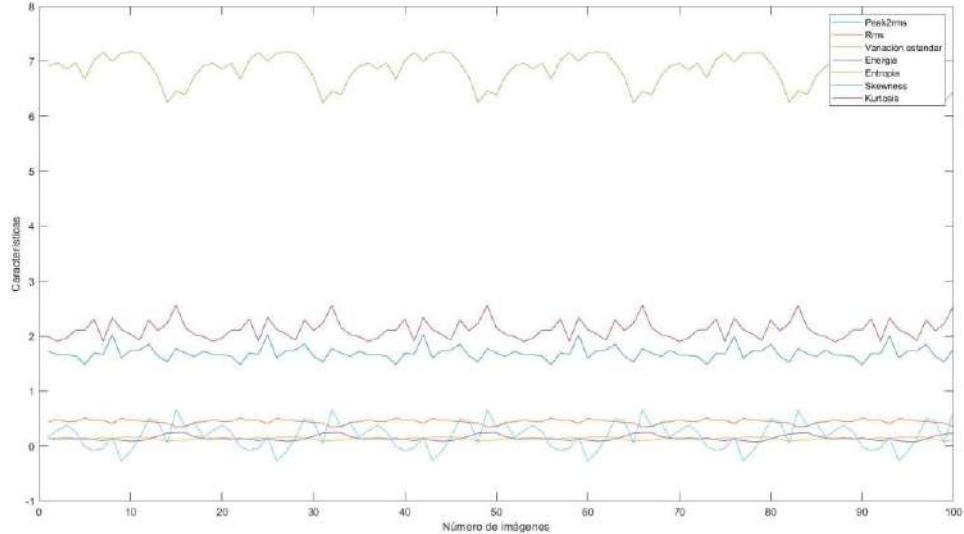


Figura 4.7 Características que describen la clase RSW punto malo (Autoría propia).

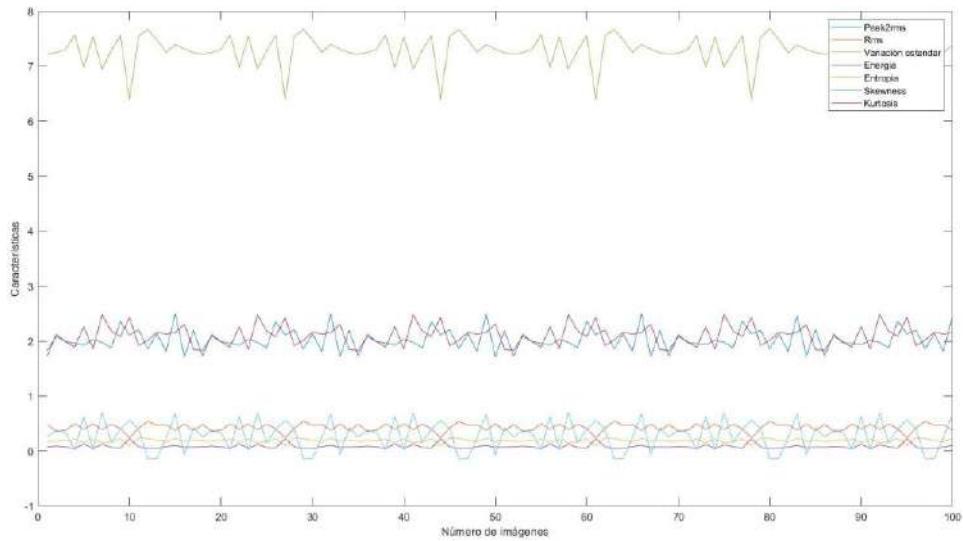


Figura 4.8 Características que describen la clase RSW doble punto (Autoría propia).

Al obtener el ventaneo de cada imagen de cada clase se le aplica la extracción de características con 10 funciones como se muestra en la Figura 4.9, obteniendo así una matriz de 10×4800 datos, donde 10 es el número de características y 4800 son el ventaneo de cada imagen por el numero de muestras (16×300). Finalmente, al aplicar LDA se obtiene una proyección de $N \times 2$ y $N \times 3$.

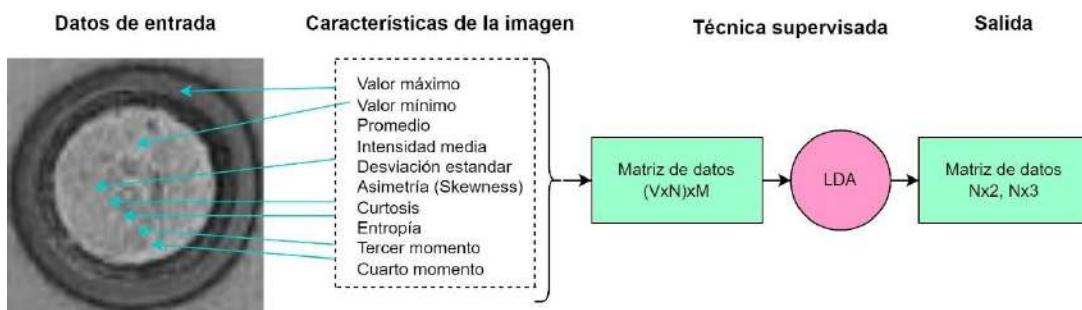


Figura 4.9 Proceso de separación de clases (Autoría propia).

En la Figura 4.10 se muestra la separación entre clases sin aplicar un ventaneo de imágenes, se aplicó la extracción de características y la técnica LDA sin embargo la separación se hizo correcta pero el rango de separación es muy pequeño.

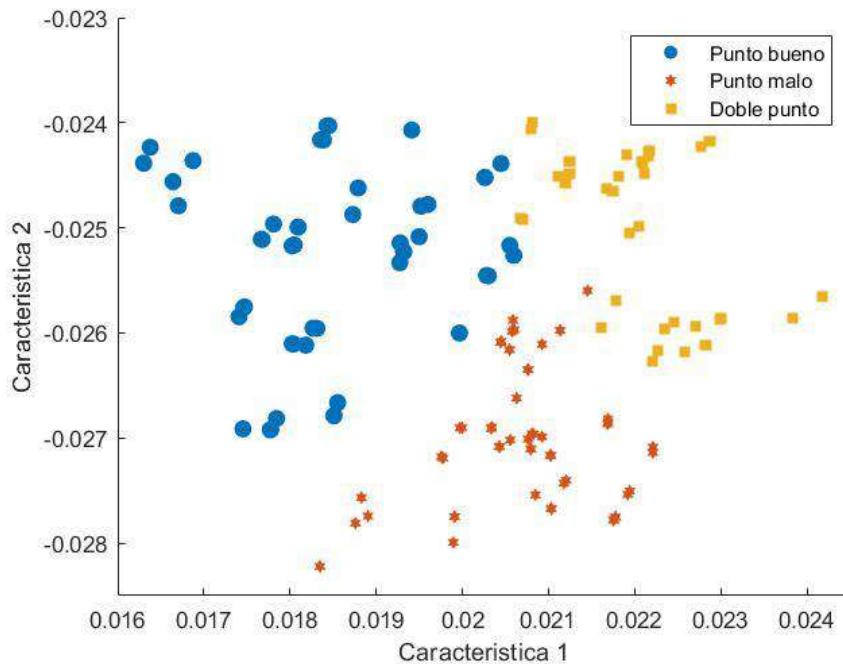


Figura 4.10 Proyección en dos dimensiones (Autoría propia).

Realizando el proceso del ventaneo y buscando las mejores características que separen mejor a las clases, se obtuvo como resultado la siguiente Figura 4.11, donde se eligieron 7 características descriptivas.

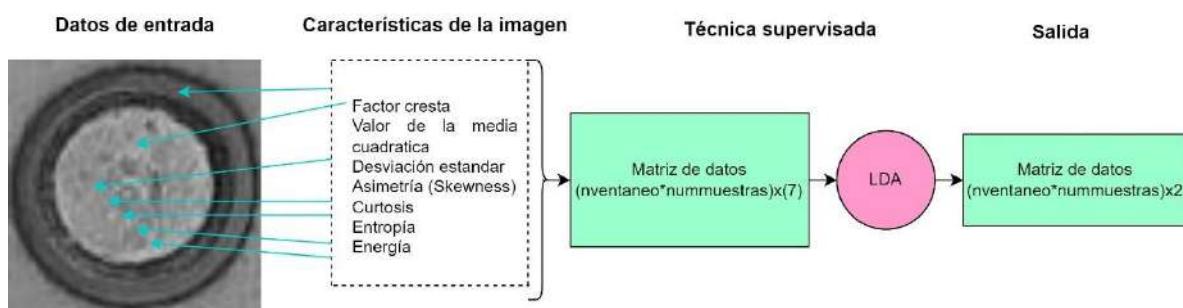


Figura 4.11 Características seleccionadas (Autoría propia).

Se observó que la característica de energía es quien controla el rango de separación entre las clases, esta gráfica se muestra en la Figura 4.12 en el cual se pueden observar las mejores dos características que separan las clases.

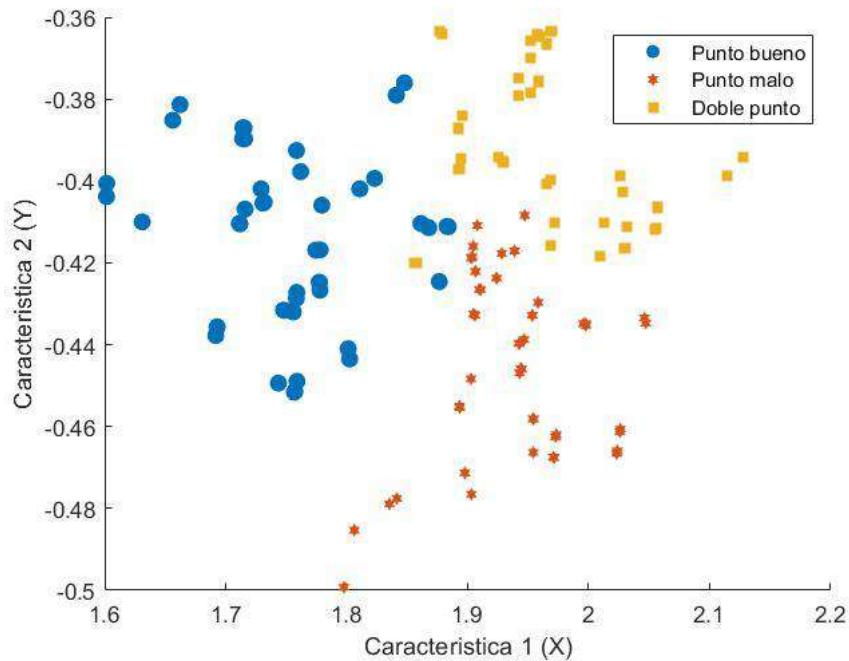


Figura 4.12 Proyección en dos dimensiones (Autoría propia).

Sin embargo, al identificar las clases se observa que unos puntos de la clase doble punto están mezclados entre la clase punto bueno, para evitar esta mezcla de datos se optó por proyectar la separación en 3 características dando como resultado la gráfica de la Figura 4.13, de esta manera los puntos entre clases no se mezclan y la separación entre clases se realiza de forma correcta.

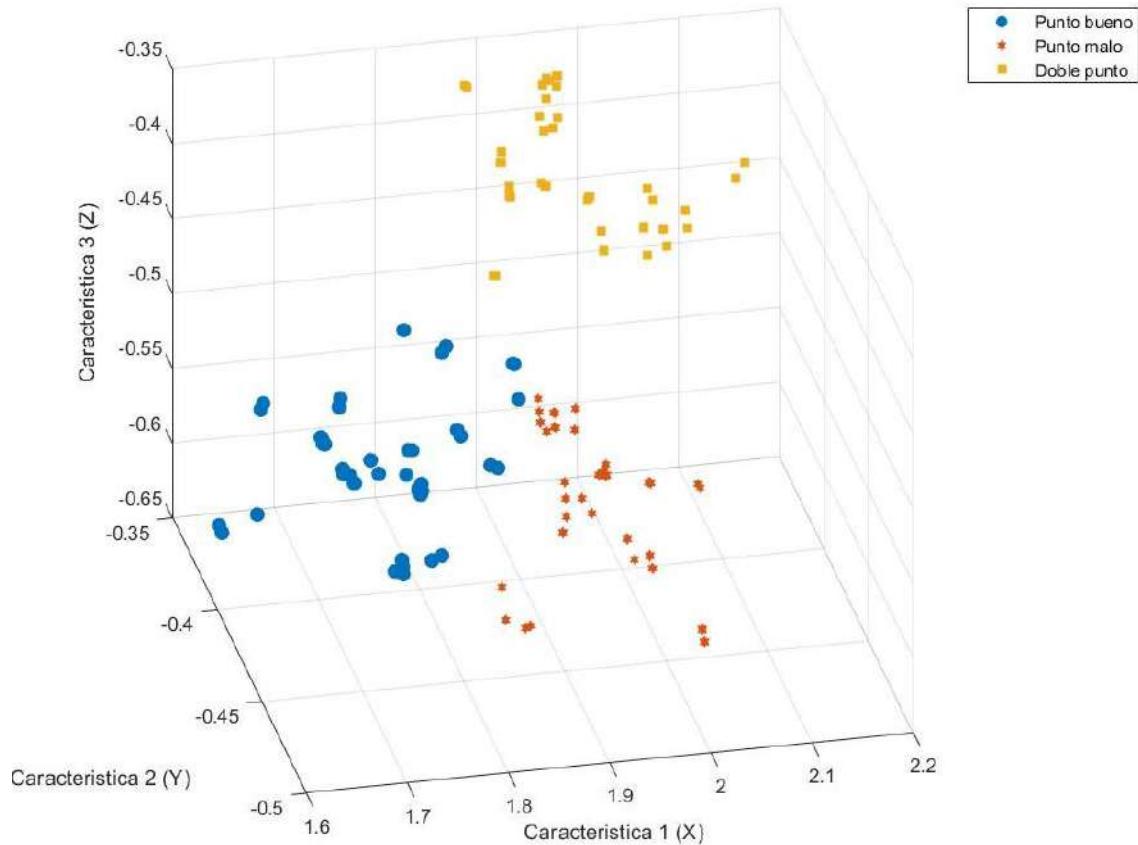


Figura 4.13 Proyección en 3 dimensiones (Autoría propia).

4.5. Modelo de aprendizaje

El modelo de aprendizaje se realizó con K-fold con $5 k$ particiones, donde se realiza la validación cruzada de 1 dato para entrenamiento y 4 datos de validación, obteniendo así la distribución de 240 datos para entrenamiento y 60 para validación, además la estrategia ‘Leaveout’ que crea k particiones dejando un dato de observación fuera de cada partición, una vez obtenido los datos para entrenamiento y validación se obtiene la siguiente estructura del modelo de aprendizaje de la Figura 4.14. En la Figura se observa que el modelo de Red neuronal tiene tres neuronas de entrada, 15 neuronas en la capa oculta y 3 neuronas en la capa de salida.

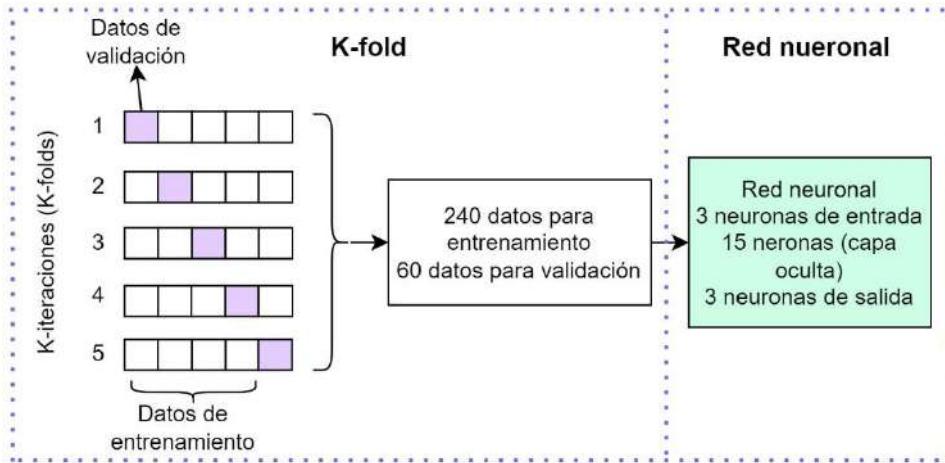


Figura 4.14 Modelo de aprendizaje (Autoría propia).

Aplicando este modelo de aprendizaje en un software se obtienen las siguientes matrices de confusión,

La matriz de confusión de la Figura 4.15 muestra el entrenamiento de la clase real y la clase predicha que realizó K-fold. Como se puede observar de la clase 1 “Punto bueno” no generó falsos positivos con las demás clases, referente al “Punto malo” (clase 2), generó 1 falso positivo con la clase 3. Finalmente, en la predicción de “Doble punto” (clase 3) clasificó correctamente todas las imágenes dando una eficiencia del 99.6%.

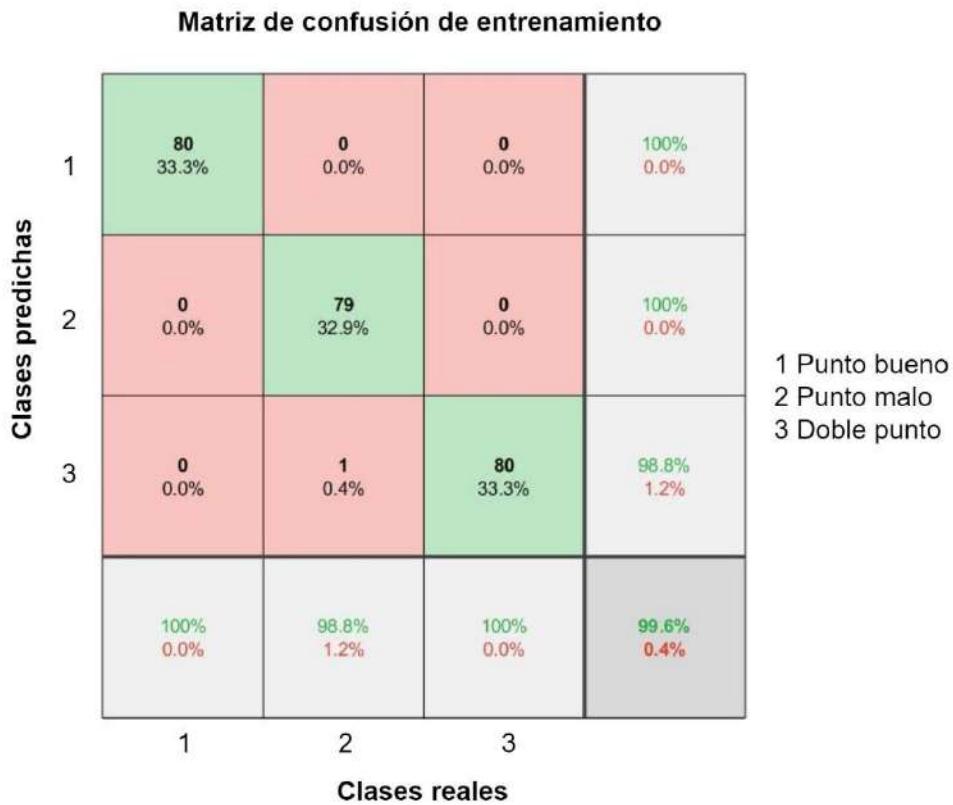


Figura 4.15 Entrenamiento K-fold (Autoría propia).

La matriz de confusión de la Figura 4.16 muestra la validación de la clase real y la clase predicha que realizó K-fold. Como se puede observar de la clase 1 “Punto bueno” no generó falsos positivos con las demás clases, referente al “Punto malo” (clase 2), generó un falso positivo con la clase 3. Finalmente, con la validación de “Doble punto” (clase 3) clasificó correctamente todas las imágenes dando una eficiencia del 98.3%.

| Matriz de confusión de validación | | | | |
|-----------------------------------|--------------|---------------|--------------|--|
| | 1 | 2 | 3 | |
| 1 | 20 33.3% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 2 | 0 0.0% | 19 31.7% | 0 0.0% | 100% 0.0% |
| 3 | 0 0.0% | 1 1.7% | 20 33.3% | 95.2% 4.8% |
| | 100% 0.0% | 95.0% 5.0% | 100% 0.0% | 98.3% 1.7% |
| Clases reales | 1 | 2 | 3 | |
| Clases predichas | | | | 1 Punto bueno 2 Punto malo 3 Doble punto |

Figura 4.16 Validación K-fold (Autoría propia).

4.5.1. Aplicación de la metodología en la GUI

Para el desarrollo de la interfaz gráfica de usuario donde se realizaron todas las pruebas se hizo en el software de código abierto Python. Inicialmente se diseñó el área de prueba y el área de testeо, sin embargo, se requiere incluir botones donde se pueda elegir una imagen RSW desde la computadora o una tomada desde una cámara (Figura 4.17).



Figura 4.17 Diseño preliminar de la GUI (Autoría propia).

En la Figura 4.18 se puede observar el nombre de la GUI el cual es “Detector de defectos RSW”, además se incluyó el logo de la Universidad Autónoma de Querétaro, el de la Facultad de ingeniería y finalmente el logo de la división de investigación y posgrado. El área de sección de prueba es donde se mostrará la imagen que se va a identificar a que tipo de clases de defecto RSW pertenece y en el área de prueba (TEST) se mostrara el tipo de defecto RSW.



Figura 4.18 Diseño final de la GUI (Autoría propia).

Se agregaron los botones que seleccionan desde donde se va a tomar la imagen, el botón “Abrir imagen” realiza la acción de abrir las carpetas que están en el ordenador para seleccionar una imagen RSW para clasificar a que clase pertenece, a su vez el botón “Capturar desde Cámara” abre una cámara para seleccionar y capturar una imagen desde la misma. En la parte de “TEST” se incluyeron unas etiquetas de las clases correspondientes que se van a clasificar, el cual cambian a color verde para mostrar a qué clase de punto pertenece la imagen seleccionada.

En la Figura 4.19 se muestra la clasificación de una imagen que no pertenece a la base original, estas imágenes para realizar las pruebas se quitaron de la base de datos para después utilizarlas en la GUI. La imagen seleccionada en la primera prueba es una imagen que pertenece a la clase punto bueno, en el panel de TESTEO la imagen se clasifico correctamente.

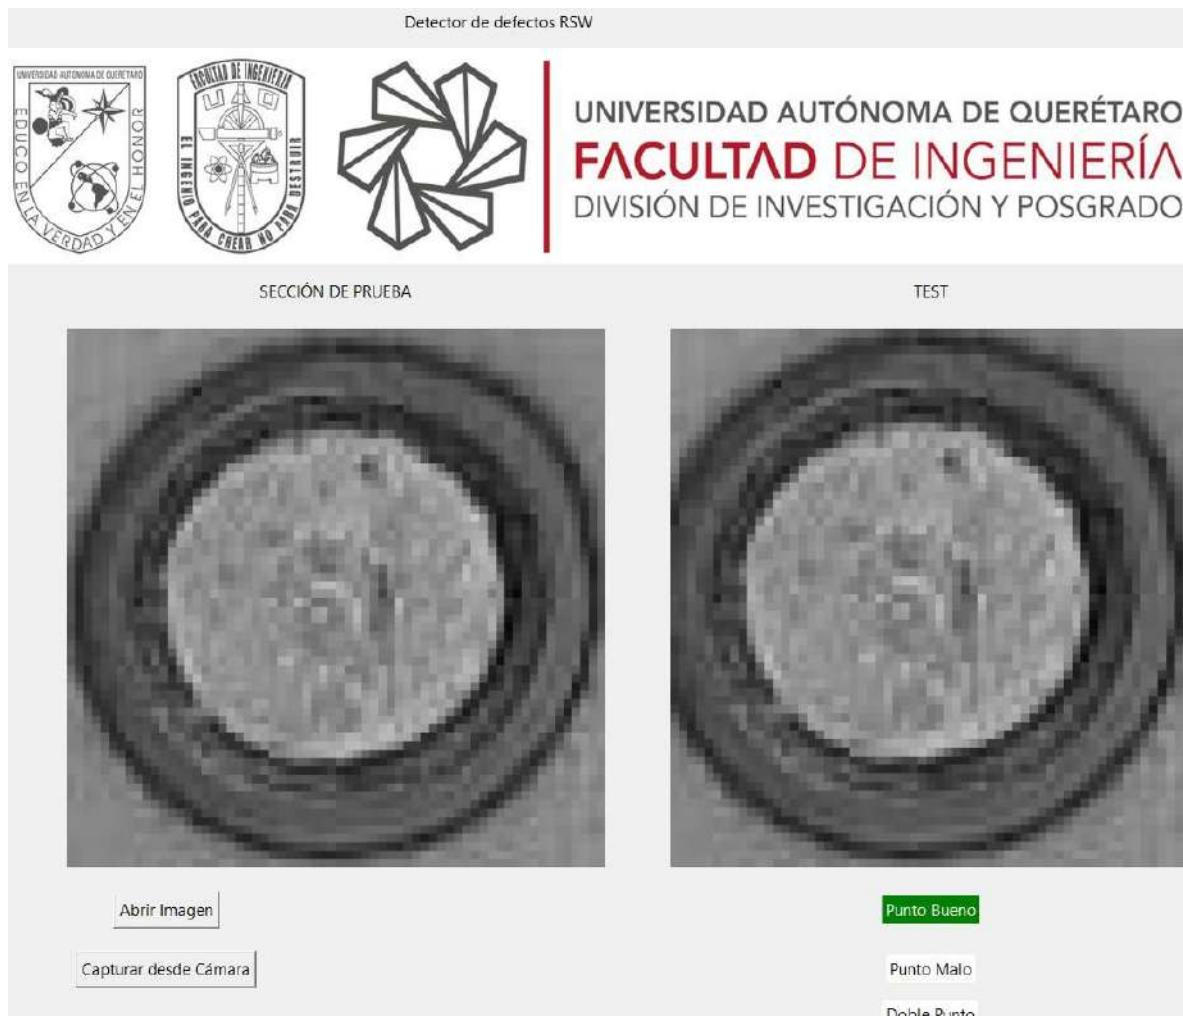


Figura 4.19 Testeo de imagen punto bueno en la GUI (Autoría propia).

La segunda prueba se realizó con una imagen de la clase punto malo, como se muestra en la Figura 4.20, la imagen se clasificó correctamente.



Figura 4.20 Testeo de imagen punto malo en la GUI (Autoría propia).

Finalmente, en la tercera (Figura 4.21) prueba se seleccionó una imagen de la clase doble punto, y como en las demás pruebas también se clasificó correctamente.



Figura 4.21 Testeo de imagen doble punto en la GUI (Autoría propia).

De igual forma se realizaron otras tres pruebas para cada clase de las imágenes transformadas y ajustadas en su intensidad, las cuales se clasificaron correctamente dando así por concluir la tabla de matriz de pruebas los resultados obtenidos en porcentajes de los algoritmos y la clasificación de las imágenes en la GUI, a su vez el porcentaje de clasificación tomando la eficiencia de las 6 pruebas realizadas.

De acuerdo con el porcentaje de los algoritmos de clasificación de imágenes RSW fue de 95%, los porcentajes esperados en este trabajo eran del 96%, sin embargo, este porcentaje fue mayor, aumentando en 2.3% concluyendo que la metodología aplicada para clasificar defectos de soldadura por unto por resistencia eléctrica da resultados satisfactorios.

En la metodología desarrollada aplicada en la GUI obtuvo un porcentaje de clasificación del 99.0%, considerando un 1.0% de error para mejoras futuras, la Tabla 4.5 muestra los resultados obtenidos de la matriz de pruebas del trabajo de investigación realizado durante la estancia en la Maestría Ciencias en Mecatrónica.

Tabla 4.5 Resultados de la matriz de pruebas.

| Identificador | Nombre | Datos de entrada | Resultado esperado |
|---------------|--|----------------------------|--------------------|
| A1 | Algoritmo de entrenamiento | Imágenes de entrenamiento | 99.6% |
| A2 | Algoritmo de testeo | Imágenes de prueba | 98.3% |
| P1 | Prueba 1 imagen clase punto bueno | Imagen original | Clase punto bueno |
| P2 | Prueba 2 imagen clase punto malo | Imagen original | Clase punto malo |
| P3 | Prueba 3 imagen clase doble punto | Imagen original | Clase doble punto |
| P4 | Prueba 4 imagen transformada clase punto bueno | Imagen transformada | Clase punto bueno |
| P5 | Prueba 5 imagen transformada clase punto malo | Imagen transformada | Clase punto malo |
| P6 | Prueba 6 imagen transformada clase doble punto | Imagen transformada | Clase doble punto |
| I1 | Interfaz gráfica de usuario | Clasificación de la imagen | 99.0% |

Esta interfaz gráfica de usuario puede ser implementada en una línea de ensamble de soldadura RSW, donde se tiene el chasis de un automóvil con puntos RSW, una cámara encargada de obtener las imágenes de interés, y finalmente un ordenador donde se muestran los resultados de clasificación de las imágenes captadas por la cámara (Figura 4.22), donde personal capacitado puede tomar decisiones a partir de esta información.

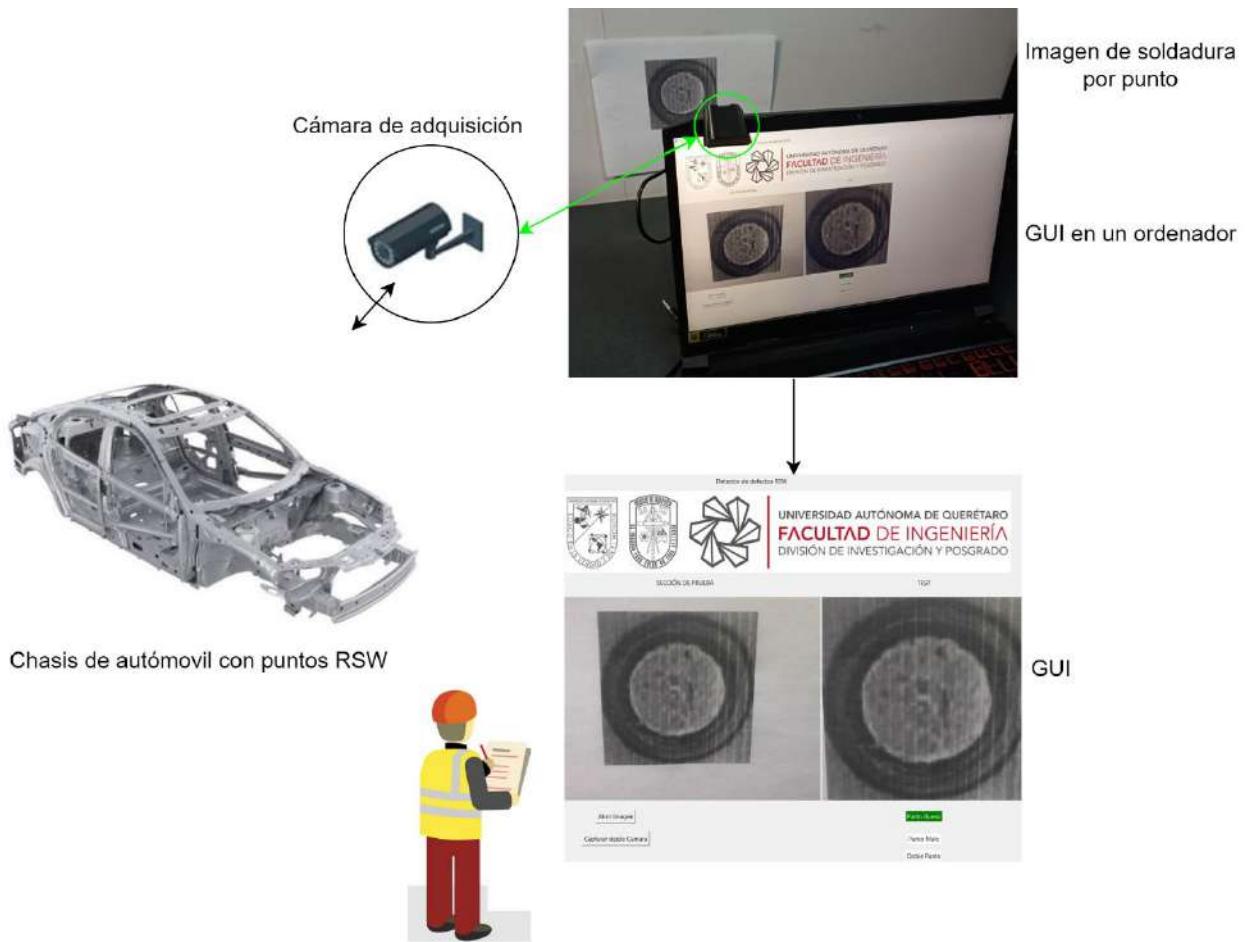


Figura 4.22 GUI en la aplicación industrial automotriz (Autoría propia).

En la Figura 4.22 se puede observar la captura de imagen desde un ordenador de un punto RSW, la distancia óptima para identificar un punto con la cámara utilizada es de un rango entre 20 cm a 60 cm, sin embargo, esta cámara puede ser cambiada por una con mayor resolución el cual podría detectar los puntos desde los 20cm hasta 2 metros, respecto a las condiciones de iluminación en esta prueba no se realizó algún ajuste por las condiciones que existen en el ambiente, pero en un entorno industrial es necesario condicionar la iluminación para que el chasis del auto no genere brillo y la cámara no pierda información en las imágenes RSW. A su vez es necesario mantener en equilibrio la cámara con el objeto de interés para evitar errores de lectura respecto a la inclinación de la imagen. Por otro lado, como se puede observar en la captura de la imagen, es de un mayor tamaño que en la prueba, por lo tanto, este ajuste de pixeles se realiza directamente desde

la GUI dando un recorte de imagen de 64x64 pixeles para su respectiva clasificación.

La Tabla 4.6 muestra las ventajas y desventajas de utilizar esta metodología propuesta, cabe destacar que a principal desventaja es no haber generado una base de datos propia el cual contengan un mayor número de muestras y un mayor numero de clases, por otra parte, la principal ventaja es dar asistencia al usuario capacitado para que realice decisiones inmediatas al observar defectos RSW.

Tabla 4.6 Ventajas y desventajas de la metodología propuesta

| Ventajas | Desventajas |
|---|--|
| Mayor precisión de clasificación | No contar con una base de datos propia |
| Identificación de características que describen una imagen RSW | Tener pocas clases de defectos RSW para realizar su clasificación |
| Tomar acciones inmediatas al identificar defectos de los puntos RSW | No aplicar esta metodología en un ambiente industrial real |
| Reducir la carga computacional al utilizar una técnica que reduce la dimensionalidad de los datos | No haber utilizado otras técnicas de aprendizaje automático para comparar resultados |
| Obtener una metodología con pasos específicos para clasificar defectos de imágenes RSW | |

Los algoritmos utilizados y desarrollados en este trabajo se muestran en el apéndice A.

La discusión con otros trabajos enfocados en la clasificación de puntos RSW se encuentra en el Apéndice B.

El artículo de investigación desarrollado en este trabajo y presentado en la conferencia Academia Journal con sede Hidalgo se muestra en el apéndice C.

5.CONCLUSIONES

Se desarrolló una metodología para la clasificación de tres clases de defectos en imágenes RSW el cual constó de 6 pasos, los resultados de clasificación muestran un alto rendimiento al obtener un 99.6% en el entrenamiento y un 98.3% en el testeo, sin embargo al aplicar esta metodología en una interfaz gráfica de usuario aplicando pruebas para identificar los defectos en imágenes distintas a las utilizadas en el entrenamiento y testeo de la red neuronal, de las 6 imágenes de prueba en la interfaz gráfica reconoció todas las imágenes en su respectiva clase. No obstante, se maneja un porcentaje del 1.7% de error en la identificación de las clases punto malo y doble punto.

El proceso para obtener la base de datos de defectos de soldadura por punto del tipo rebaba se llevó a cabo utilizando imágenes digitales, lo que permitió la identificación de tres clases distintas de defectos: "punto bueno", "punto malo" y "doble punto". Aunque inicialmente se seleccionaron 25 imágenes para cada clase, se amplió el conjunto de datos mediante transformaciones geométricas y ajustes de intensidad, alcanzando un total de 100 imágenes por clase. Esta expansión fue esencial para proporcionar un conjunto amplio y variado de imágenes, facilitando así el análisis y la comprensión de las características de los defectos presentes en las soldaduras.

El desarrollo del algoritmo para separar las clases de defectos RSW se realizó mediante la técnica supervisada LDA, identificando 7 características estadísticas mencionadas de la Tabla 2.4, que separaron las tres clases de defectos con la proyección de 3 ejes, esta proyección de datos se utilizó para desarrollar una red neuronal artificial como clasificador de defectos RSW, lo cual tuvo 98.3% de eficiencia, precisión alta para identificar las 3 clases obtenidas de la base de datos. Su configuración inicial fue de 3 neuronas de entrada, 10 neuronas en la capa oculta y tres neuronas de salida, sin embargo, al aumentar a 15 neuronas en la capa oculta se obtuvo una mayor precisión en la identificación de imágenes RSW.

La eficiencia y validez del modelo con LDA y K-fold para la clasificación de defectos de imágenes RSW depende de la cantidad de clases RSW y el número de imágenes de cada clase, al obtener un 98.30% de eficiencia se determina que el modelo tiene un porcentaje de precisión muy alto para la identificación de defectos de soldadura en las tres clases especificadas. Este alto rendimiento sugiere que el modelo propuesto es una herramienta adecuada para la detección de defectos de soldaduras por punto en aplicaciones industriales, ya que con este diagnóstico el personal encargado podría tomar acciones que permitan corregir las fallas y a su vez mejorar la calidad y eficiencia del proceso de la soldadura. Sin embargo, es importante evaluar y ajustar el modelo con un mayor número de clases, y un mayor número de imágenes de cada clase, de tal manera que la validez del modelo sea robusta frente a diferentes condiciones y tipos de defectos.

El desarrollo de un clasificador utilizando técnicas de inteligencia artificial, basado en los patrones identificados previamente, permite aplicar el conocimiento adquirido a imágenes distintas de las utilizadas en el entrenamiento, validando así la eficacia y la generalización del clasificador. Este enfoque integrado no solo mejora la eficiencia y la precisión en la detección de defectos de soldadura a través de una interfaz gráfica de usuario, sino que también tiene el potencial de mejorar los procesos de control de calidad en la industria, contribuyendo así al avance y la fiabilidad de la fabricación de productos.

6.PROSPECTIVAS

Realizar una investigación de las variables que se utilizan para generar los puntos RSW, de modo que estas puedan realizarse un estudio de como influyen en la generación de defectos en los puntos RSW.

Generar una base de datos propia con distintas clases de imágenes RSW, con un mayor número de muestras, con la finalidad de aplicar la metodología propuesta y discutir resultados de eficiencia del modelo propuesto. De igual manera utilizar distintas técnicas de aprendizaje para la clasificación de defectos con la intención de comparar resultados y ventajas al aplicar distintas técnicas.

Para generalizar el modelo de aprendizaje automático se recomienda utilizar un mayor número de clases y un mayor número de muestras, de modo que el aumento de datos pueda dar mayor confiabilidad en la precisión de clasificación.

Incorporar funcionalidades en la GUI que permitan al usuario proporcionar retroalimentación a partir de historiales sobre la precisión de las predicciones del modelo, ayudando así a mejorar continuamente el modelo, además de añadir características adicionales a la GUI, como la capacidad de realizar anotaciones en las imágenes, almacenar historiales de defectos y generar reportes automatizados.

Realizar pruebas extensivas del modelo en entornos de producción reales para evaluar su rendimiento en condiciones operativas para realizar ajustes necesarios.

REFERENCIAS

- Akkaş, N. (2017). Welding time effect on Tensile-Shear loading in resistance spot welding of SPA-H weathering steel sheets used in railway vehicles. *Acta Physica Polonica A*, 131(1), 52-54. <https://doi.org/10.12693/aphyspola.131.52>
- Alghannam, E., Lu, H., Ma, M., Cheng, Q., Gonzalez, A. A., Zang, Y., & Li, S. (2019). A novel method of using vision system and fuzzy logic for quality estimation of resistance spot welding. *Symmetry*, 11(8), 990. <https://doi.org/10.3390/sym11080990>.
- Alvarado-Hernandez, A. I., Zamudio-Ramirez, I., Jaen-Cuellar, A. Y., Osornio-Rios, R. A., Donderis-Quiles, V., & Antonino-Daviu, J. A. (2022). Infrared Thermography Smart Sensor for the Condition Monitoring of Gearbox and Bearings Faults in Induction Motors. *En Sensors* (Vol. 22, Número 16). <https://doi.org/10.3390/s22166075>.
- Azuela, J. H. (2013). Visión artificial: rasgos descriptores para el reconocimiento de objetos. Ra-ma.
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer Verlag.
- Boriwal, L., Sarviya, R. M., & Mahapatra, M. M. (2017). Failure modes of spot welds in quasi – static tensile – shear loading of coated steel sheets. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2017.02.261>
- Bravo, C. F. (2015). Inspección de soldadura MIG/MAG de piezas metálicas utilizando técnicas de visión artificial y procesamiento de imágenes (Bachelor's thesis).
- Chollet, F. (2021). Deep learning with Python. Simon and Schuster, Capítulo 5.
- Cuevas, E., Cortés, M. D., & Méndez, J. O. C. (2017). Tratamiento de imágenes con MATLAB.
- Dai, W., Li, D., Ding, T., Jiang, Q., Wang, D., Wang, H., & Peng, Y. (2021). Deep Learning Assisted Vision inspection of resistance spot welds. *Journal of Manufacturing Processes*, 62, 262-274. <https://doi.org/10.1016/j.jmapro.2020.12.015>
- Dai, W., Li, D., Ding, T., Wang, H., & Peng, Y. (2022). Deep learning approach for defective spot welds classification using small and class-imbalanced datasets. *Neurocomputing*, 477, 46-60. <https://doi.org/10.1016/j.neucom.2022.01.004>
- Díaz-Saldaña, G., Osornio-Ríos, R. A., Zamudio-Ramírez, I., Cruz-Albarrán, I. A., Trejo-Hernández, M., & Antonino-Daviu, J. A. (2023). Methodology for Tool Wear Detection in CNC Machines Based on Fusion Flux Current of Motor and Image

Workpieces. En Machines (Vol. 11, Número 4).
<https://doi.org/10.3390/machines11040480>.

Duan, R., Luo, Z., Li, Y., Zhang, Y., & Liu, Z. M. (2014). Novel postweld heat treatment method for improving mechanical properties of resistance spot weld. Science and Technology of Welding and Joining, 20(2), 100-105.
<https://doi.org/10.1179/1362171814y.0000000262>

Duda, R. O., Hart, P. E., & Stork, D. G. (2012). Pattern classification. John Wiley & Sons.

Duda, R. O., Hart, P. E., Hart, P. E., & Stork, D. G. (2001). Pattern classification. Wiley-Interscience.

Espinosa, M. E., Esteves Cano, C., & Moreno Blat, J. M. (2017). Capacidades de los servicios de investigación desarrollo e innovación en la industria automotriz mexicana. ProMéxico.

Gonzalez, R. C., & Woods, R. E. (2017). Digital Image Processing, Global Edition. Pearson Higher Education.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.

Hussain, W., Sadiq, M. T., Siuly, S., & Rehman, A. U. (2021). Epileptic seizure detection using 1D-convolutional long short-term memory neural networks. En Applied Acoustics (Vol. 177). <https://doi.org/10.1016/j.apacoust.2021.107941>.

Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies. MIT press.

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

Maravall, D., & Allende, G. (1993). Reconocimiento de formas y visión artificial. Rama.

Marcos, A., Martínez de Pisón Espinoza, F. J., Parnía Espinoza, A. V., Alba Elias, F., Joaquín Ordiros Meré, & Eliseo Vergara González. (2006). Técnicas y algoritmos básicos de visión artificial (Vol. 24). Logroño.

Martinsanz, G. P., & De La Cruz García, J. M. (2008). Ejercicios resueltos de visión por computador. Alfaomega.

Mitchell, M., T. (1997). Machine Learning. McGraw-Hill.

Molera, S., P. (1992). Soldadura industrial: clases y aplicaciones (Vol. 56). Marcombo.

Pajares, Martinsanz, G., Cruz García, J. M. (2007). Ejercicios Resueltos de Visión por Computador. España: Ra-Ma S.A. Editorial y Publicaciones.

Podržaj, P., & Simončič, S. (2013). A machine vision-based electrode displacement measurement. *Welding in The World*, 58(1), 93-99. <https://doi.org/10.1007/s40194-013-0086-7>

Poole, D. L., & Mackworth, A. K. (2017). Artificial Intelligence. Cambridge University Press.

PUTIER, S. (2016). VB.NET y Visual Studio 2015. Ediciones ENI.

Resendiz-Ochoa, E., Morales-Hernandez, L. A., Cruz-Albarrán, I. A., & Alvarez-Junco, S. (2022). Induction Motor Failure Analysis using Machine Learning and Infrared Thermography. En 2022 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC). <https://doi.org/10.1109/ropec55836.2022.10018653>.

Sanghadiya, F., & Mistry, D. (2015). Surface Defect Detection in a Tile using Digital Image Processing: Analysis and Evaluation. En International Journal of Computer Applications (Vol. 116, Números 10, pp. 33-35). <https://doi.org/10.5120/20375-2592>.

Torres, J. (2020). Python deep learning: Introducción práctica con Keras y TensorFlow 2. Alpha Editorial.

Valtierra-Rodriguez, M., Rivera-Guillen, J. R., Basurto-Hurtado, J. A., De-Santiago-Perez, J. J., Granados-Lieberman, D., & Amezquita-Sanchez, J. P. (2020). Convolutional Neural Network and Motor Current Signature Analysis during the Transient State for Detection of Broken Rotor Bars in Induction Motors. En Sensors (Vol. 20, Número 13). <https://doi.org/10.3390/s20133721>.

Wang, X.-J., Zhou, J.-H., Yan, H.-C., & Pang, C. K. (2017). Quality monitoring of spot welding with advanced signal processing and data-driven techniques. En Transactions of the Institute of Measurement and Control (Vol. 40, 7, pp. 2291-2302). <https://doi.org/10.1177/0142331217700703>.

Yang, Y., Zheng, P., He, H., Zheng, T., Wang, L., & He, S. (2018). An Evaluation Method of Acceptable and Failed Spot-Welding Products Based on Image Classification with Transfer Learning Technique. En Proceedings of the 2nd International Conference on Computer Science and Application Engineering. <https://doi.org/10.1145/3207677.3278004>.

Ye, S., Guo, Z., Zheng, P., Wang, L., & Lin, C. (2017). A Vision Inspection System for the Defects of Resistance Spot Welding Based on Neural Network. En Lecture Notes in Computer Science (pp. 161-168). https://doi.org/10.1007/978-3-319-68345-4_14.

Younès, D., Alghannam, E., Tan, Y., & Lü, H. (2020). Enhancement in quality estimation of resistance spot welding using vision system and Fuzzy Support Vector machine. *Symmetry*, 12(8), 1380. <https://doi.org/10.3390/sym12081380>

Zhang, H., & Senkara, J. (2017). Resistance Welding: Fundamentals and applications (Second Edition). CRC Press.

APENDICES

Apéndice A Algoritmo desarrollado

| Función aplicada |
|--|
| Generar la muestra de la base de datos |
| Selección de imagen |
| Escala de grises de la imagen |
| Umbralizar la imagen |
| Binarizar la imagen |
| Selección del punto, Recorte |
| Guardar imagen 64x64 pixeles |
| Separación de clases |
| Selección visual de la imagen |
| Etiquetado de clases |
| Verificación de etiquetado con el umbral de cada clase |
| 3 clases obtenidas |
| Aumento del número de imágenes |
| Transformaciones geométricas (espejo y rotación) |
| Ajuste de intensidad |
| Aplicar técnica LDA |
| Selección y ventaneo de imágenes |
| Selección de características de cada imagen |
| Cálculo de funciones discriminantes |
| Clasificación |
| Modelo de aprendizaje |
| Selección de conjunto de entrenamiento |
| Selección de conjunto de validación |
| Entrenamiento de la red neuronal |
| Validación de la red neuronal |
| Guardar el modelo predictivo |
| Creación de la interfaz gráfica de usuario |
| Cargar el modelo predictivo |
| Programación de objetos para visualizar la imagen |
| Programación de objetos para seleccionar imagen |
| Programación de objetos para clasificar la imagen |
| Programación de objetos para visualizar el resultado de clasificación de la imagen |

Apéndice B Discusión de clasificación RSW

La Tabla apéndice B muestra una comparación entre los distintos trabajos que han realizado una clasificación en imágenes de defectos RSW, como se puede observar los primeros dos trabajos clasificaron las imágenes en base a un valor aceptable e inaceptable y un rango del 0 al 10 para determinar la calidad de la soldadura, sin embargo, no muestran una precisión o eficiencia en su método de clasificación. Los siguientes 4 trabajos discutidos si realizan una clasificación del concluyen con una precisión, sin embargo, el presente proyecto presenta mejores resultados de clasificación obteniendo hasta un 98.3%, por otra parte, cabe mencionar que el trabajo de Dai et al. (2022) realizó una clasificación con un mayor número de clases, de acuerdo con estos datos presentados se recomienda aumentar el número de clases para el presente trabajo y realizar una comparativa entre ambos para indicar la eficiencia de la metodología presentada en clasificación de defectos RSW.

Tabla Apéndice B Métodos para clasificar defectos RSW

| Trabajo | Método | Defectos detectados | Precisión |
|----------------------------------|---|--|-------------------------|
| Bravo (2015) | Inspección visual (morfología matemática y umbralización por método otsu) | Considero a los puntos RSW en general en dos valores | Aceptable e inaceptable |
| Younes et al. (2020) | Máquina de soporte vectorial difusa | Defectos y calidad de la soldadura mediante inspección ultrasónica | Rango del 0 al 10.0 |
| Dai et al. (2021) | Faster R-CNN | Punto bueno, punto malo | 92.04% |
| Dai et al. (2022) | Transfer ResNet-50+ | Soldadura de borde, Doble punto Pseudosoldaduras, Rebaba Distorsión, Punto flameado, Punto bueno | 97.8% |
| Artículo presentado (Apéndice C) | CNN | Punto bueno, Punto malo y Doble punto | 98.3% |
| Presente trabajo | Metodología propuesta | Punto bueno, Punto malo, Doble punto | 98.3% |

Apéndice C Artículo publicado

ACADEMIA JOURNALS
OPUS PRO SCIENTIA ET STUDIUM

OCTUBRE 18, 19, Y 20 DE 2023

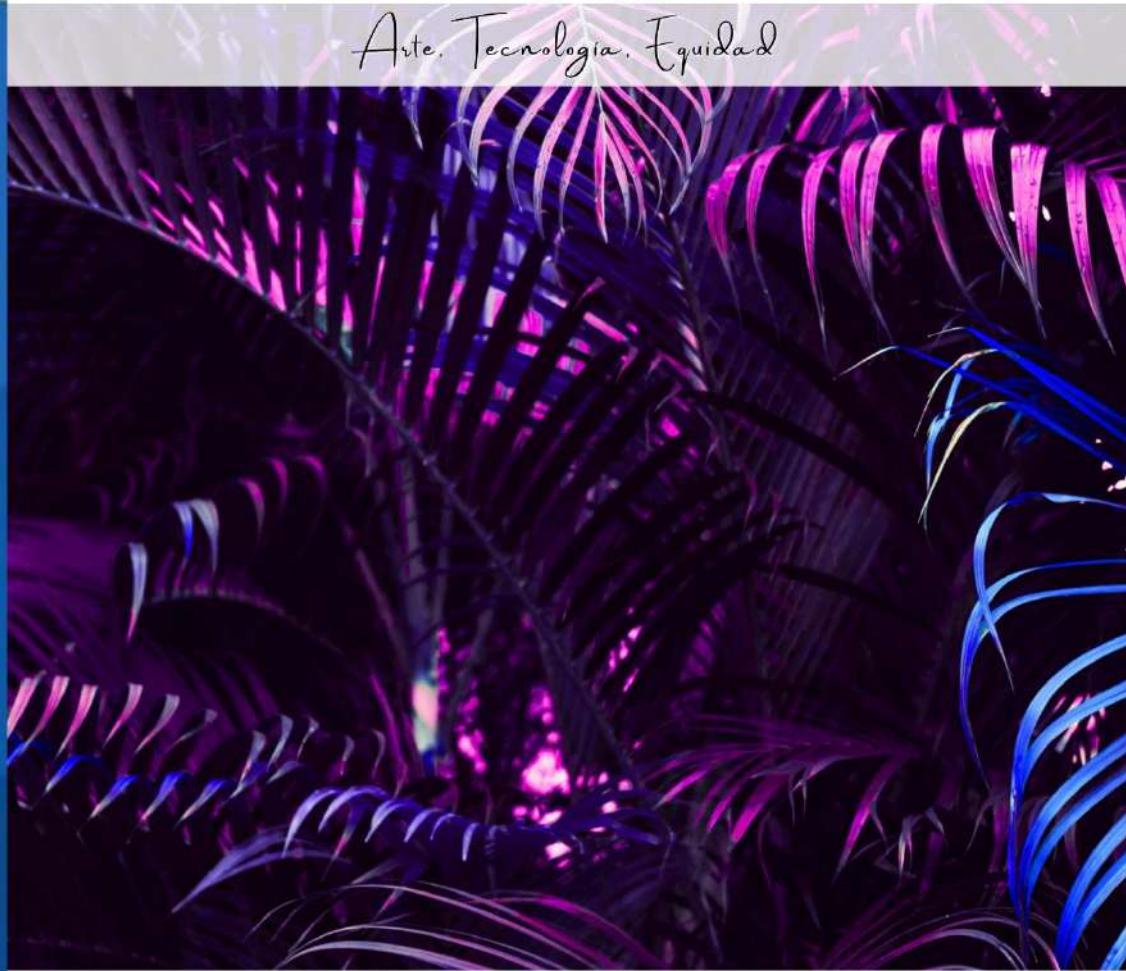

Universidad Politécnica
Metropolitana de Hidalgo





ARTÍCULOS DEL CONGRESO INTERNACIONAL DE INVESTIGACIÓN ACADEMIA JOURNALS HIDALGO 2023

Arte. Tecnología. Equidad



ELIBRO ONLINE CON ISSN 1946-5351 | VOL. 15, NO. 9, 2023



Congreso Internacional de Investigación Academia Journals

ISSN

ISSN 1946-5351 online
No. 15, 2023*

*El número 1 fue utilizado en 2009. Cada año siguiente ha recibido el número secuencial.

ISSN asignado a Academia Journals por el U.S. ISSN Center, una rama de la Biblioteca del Congreso de Estados Unidos. Varios portales independientes proporcionan servicios de verificación de la asignación de un ISSN a una publicación periódica. Entre los más utilizados se encuentran los siguientes: WORLDCAT:
<https://www.worldcat.org/account/?page=searchitems>

Consejo académico

Dr. Rafael Moras (San Antonio, EEUU)
MA Aní Alegre (Austin, EEUU)
Dr. Ángel Esparza (Houston, EEUU)
Lic. David Moras (San Antonio)
MC Constantino Moras Sánchez (Orizaba, México)
Dr. Eloy Mendoza Machain (Morelia, México)
Dr. Pedro López Eiroá (CDMX, México)
Dr. Victor Mendoza (Puebla, México)
Dr. Albino Rodríguez Díaz (Tepic, México)
Vicerrector Dante Agatón (Morelia, México)

Diseño y publicidad

contacto@academajournals.com

Comentarios y sugerencias

contacto@academajournals.com
+1 (210) 415-3353
3760 E. Evans
San Antonio TX 78259 USA
www.academajournals.com

Política de copyright

Con el fin de maximizar el valor para los autores de sus publicaciones en AJ, se observan las políticas de copyright aquí descritas. Academia Journals protegerá los intereses de los autores y de las instituciones donde ellos laboran. Como requisito para publicar en AJ, todos los autores y la institución donde ellos laboran transfieren a AJ cualquier derecho de copyright que tengan en su artículo. El copyright se transmite cuando el artículo es aceptado para su publicación. La asignación de copyright es nula y terminada en caso de que el artículo no sea aceptado para publicación.

Para corresponder a la transferencia de los derechos de autor, AJ cede a los autores y a las instituciones donde ellos laboran el permiso y derecho de hacer copias del artículo publicado y utilizarlo para fines académicos. El autor retiene siempre los derechos de patentes descritas en el artículo.

Después de que el artículo haya sido aceptado para su publicación en AJ, y dado que el copyright ha sido ya transferido, cualquier cambio o revisión al material debe hacerse solamente con la autorización de AJ.

Indexación

Desde 2015, los trabajos presentados en el congreso cuentan con indexación por la compañía EBSCO (EBSCOHOST) de Ipswich, Massachusetts, Estados Unidos. Para la verificación de los títulos indexados por este importante servicio de databases, consultar los enlaces
<https://www.ebscohost.com/academic/fuente-academica-plus>,
<https://www.ebscohost.com/titleLists/fap-subject.htm> o
<https://www.ebscohost.com/titleLists/fap-subject.pdf>

Academajournals.com es una división de PDHTech, LLC, organización proveedora de servicios editoriales, educacionales y de entrenamiento profesional ubicada en San Antonio, Texas, EEUU.

Clasificación de Errores en Soldadura por Punto mediante Procesamiento de Imágenes y Red Neuronal Convolucional

Ing. Alfonso Alejo-Ramirez¹, Dr. Irving A. Cruz-Albarran²,
Dr. Luis A. Morales-Hernandez³, Dr. Roque A. Osornio-Rios⁴

Resumen— La soldadura por punto por resistencia eléctrica (RSW) es uno de los métodos de unión más utilizados en la industria automotriz en México, al garantizar uniones robustas, duraderas y seguras, cada auto cuenta con alrededor de 3000 puntos RSW, a este ritmo de producción es necesario aplicar un sistema que verifique la calidad de los puntos RSW. En este artículo se propone un sistema de clasificación de defectos (“punto bueno”, “punto malo” y “doble punto”) en imágenes de soldadura por punto por resistencia eléctrica mediante el modelo de una red neuronal convolucional (CNN). Las imágenes son obtenidas y seleccionadas de una base de datos, posteriormente se realiza el procesamiento de imágenes y se les aplica un modelo CNN. Se valida la metodología para resaltar los defectos de las imágenes, la construcción del clasificador y finalmente la clasificación de las imágenes; obteniendo el 98.3% de eficiencia en cuanto a la clasificación de las tres clases.

Palabras clave— soldadura por punto, CNN, clasificación de imágenes, defectos de soldadura, RSW.

Introducción

La soldadura por punto por resistencia eléctrica (RSW) es un proceso fundamental en la industria automotriz que se utiliza para unir dos o más piezas metálicas mediante la aplicación de calor y presión en puntos específicos. Esta técnica de unión se ha convertido en un pilar esencial en la fabricación de vehículos, ya que garantiza conexiones robustas y duraderas, contribuyendo a la integridad estructural y seguridad de los automóviles (Akkaş, 2017). Recientemente, ha existido una creciente demanda en las empresas automotrices para disminuir la cantidad de rebabas en los puntos de soldadura, sin afectar la calidad en las uniones, lo cual puede repercutir en ahorros significativos en tiempo y gastos de producción (Alghannam et al., 2019).

Existen varios métodos utilizados para verificar la calidad de las soldaduras por RSW en la industria automotriz que han sido estudiados en los últimos años, los cuales se mencionan a continuación: Inspección visual, pruebas de penetración, pruebas destructivas y ultrasonido. En cuanto a la inspección visual es uno de los métodos más simples pero efectivos para evaluar la calidad de las soldaduras. Los operadores examinan visualmente las soldaduras en busca de defectos visibles, como grietas, porosidades o falta de penetración (Podrzaj & Simončič, 2013). Por otro lado, las pruebas de penetración son no destructivas, estas pruebas implican la aplicación de líquidos penetrantes o partículas magnéticas que revelan irregularidades en la superficie de la soldadura, de esta forma pueden revelar defectos internos que no son visibles a simple vista (Duan et al., 2014). A su vez, las pruebas destructivas se realizan en muestras de soldadura para evaluar la resistencia y la integridad de la unión. Esto puede implicar pruebas de tracción o corte para determinar la fuerza necesaria para romper la unión. Finalmente, el método de ultrasonido utiliza ondas de sonido de alta frecuencia para evaluar la integridad interna de la soldadura. Los equipos de ultrasonido emiten ondas que se reflejan en las interfaces entre materiales, permitiendo a los operadores detectar posibles defectos internos (Hussain et al., 2021). Estos métodos se enfocan en evaluar tanto la integridad estructural como las características eléctricas de las uniones soldadas.

Recientemente han existido trabajos importantes en la inspección de la calidad RSW aplicando directamente métodos novedosos de procesamiento de imágenes. Uno de los trabajos importantes es el de Younès et al. (2020), quienes utilizaron la inspección visual en una estación robotizada de RSW en las plantas de fabricación de automóviles usando procesamiento de imágenes y una máquina de vectores de soporte difuso (FSVM), extrajeron características de la pepita de soldadura de forma elíptica con el fin de obtener un modelo tridimensional con el método de reconstrucción de la superficie soldada, dividieron sus muestras en tres grupos y el algoritmo de aprendizaje FSVM utiliza funciones de pertenencia para clasificar las imágenes de RSW de acuerdo con la calidad de la soldadura. Otro de los trabajos sobresalientes es el de Dai et al. (2022), en donde realizaron la clasificación de 7 grupos de imágenes de RSW, propusieron el equilibrio de las redes antagonistas generativas (BAGAN's) y la penalización del gradiente (GP), para de esta forma generar diversas imágenes, así mismo construyeron un clasificador de imágenes con una red

¹Estudiante de la Maestría en Ciencias (Mecatrónica), Facultad de Ingeniería de la Universidad Autónoma de Querétaro, campus San Juan del Río, México. alejor25@alumnos.uaq.mx (autor correspondiente)

² Profesor investigador de la Universidad Autónoma de Querétaro, campus San Juan del Río México. irving.cruz@uaq.mx

³ Profesor investigador de la Universidad Autónoma de Querétaro, campus San Juan del Río México. luis.morales@uaq.mx

⁴ Profesor investigador de la Universidad Autónoma de Querétaro, campus San Juan del Río México. roar@uaq.mx

neuronal profunda pre-entrenada que emplea un método de aprendizaje por transferencia, luego las imágenes generadas por BAGAN-GP se agregan al conjunto de datos de entrenamiento para mejorar el clasificador y obtener un mejor rendimiento de clasificación, de esta forma demostraron que su método propuesto puede generar imágenes RSW de manera eficiente y mejorar el rendimiento de clasificación en la inspección industrial.

Los métodos de inspección mencionados anteriormente utilizan métodos que presentan desventajas en la dimensionalidad de los datos, como es el caso de la FSVM que puede presentar problemas de dimensionalidad de datos, debe tener datos con características cuidadosamente diseñadas para lograr buenos resultados, se debe configurar un kernel y un parámetro de regularización. Por otro lado, el método BAGAN's requiere de un conjunto de datos de entrenamiento de lo contrario presenta problemas de estabilidad, como el colapso del generador, donde el generador produce imágenes similares una y otra vez. Esto puede requerir técnicas adicionales, como la regularización o el ajuste fino, para lograr resultados deseables.

Este artículo presenta la clasificación de imágenes de soldadura por punto utilizando una red neuronal convolucional (CNN), al ser excelentes para tareas de clasificación y detección de objetos en imágenes, ya que están diseñadas específicamente para aprender representaciones jerárquicas y características relevantes en datos visuales, son altamente efectivas para detectar defectos en las imágenes de soldadura por puntos. Pueden aprender a identificar características sutiles que podrían indicar problemas en la calidad de la soldadura, como grietas, porosidades o discontinuidades. Las condiciones de soldadura pueden variar debido a factores como la calidad del material, la temperatura o la configuración de la máquina. Por estas razones se optó por utilizar una CNN para clasificar 3 grupos de imágenes de soldadura por punto, por ser capaces de adaptarse a estas variabilidades y seguir siendo precisas en la detección de defectos.

Metodología

Clasificación de puntos de soldadura

En este artículo se propone un método para analizar los defectos de RSW, incluido el aumento de datos, los defectos de la soldadura por punto, la clasificación de imágenes y la construcción del clasificador. Las imágenes seleccionadas están disponibles en: <https://github.com/githammer16/spot-welding-defect-detection-using-by-CNN>. El método propuesto se presenta en la Figura 1. De entrada, se cuentan con imágenes a color, las cuales posteriormente se transforman a escala de grises. Se tienen 19 imágenes de la clase "punto bueno", 17 imágenes de la clase "punto malo" y 34 imágenes de la clase "doble punto". Mediante un procesamiento de imágenes se hace el aumento de datos utilizando las transformaciones geométricas espejo y rotación. Posteriormente se construye el clasificador de puntos de soldadura defectuosos utilizando una CNN, el principal desafío es obtener la función Max-pooling y la función Softmax adecuados para la capa de clasificación. Finalmente se obtiene el clasificador entrenado para indicar a qué clase pertenece una nueva imagen de RSW.

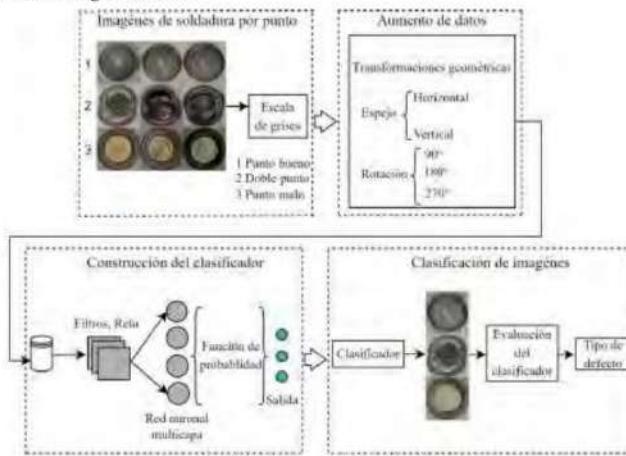


Figura 1. Método de clasificación de imágenes.

Defectos en imágenes

Dado que no existe una base de datos con imágenes de RSW que este previamente etiquetada y distribuida en clases, se crea una a partir de una base de datos de imágenes publicadas por Dai et al. (2022). De estas imágenes se obtienen los puntos de soldadura (Figura 2) de los cuales se pueden identificar 3 clases.

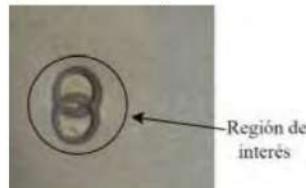


Figura 2. Puntos de soldadura en placas de acero.

De estas imágenes se seleccionan los RSW y se recortan en imágenes de 64x64 pixeles, se le aplica un filtro a escala de grises y se etiquetan a partir de sus características y defectos comunes, al identificar las imágenes obtenidas los defectos pueden clasificarse en 3 clases “punto bueno”, “mal punto” y “doble punto”. En la Figura 3 se pueden observar las 3 clases de los defectos RSW.

Un “punto bueno” de soldadura significa que en el círculo interior presenta uniformidad, no existe una rebaba y en la parte externa se muestra el relieve que determina que existió una buena conductividad eléctrica en los electrodos, una presión adecuada y un buen control de tiempo-temperatura. Un “mal punto” presenta una circunferencia no uniforme, la corriente eléctrica y la presión en los electrodos no es la adecuada, lo cual puede presentar una soldadura fría (unión inadequada entre piezas), en la unión pueden existir deformaciones de material o fractura permanente. Por último, el “doble punto” se refiere a que dos puntos se superponen entre sí, puede producirse una falta de fusión; en caso de que la corriente eléctrica o la presión aplicada no sean uniformes para ambos puntos, un mal control en la aplicación puede provocar deformaciones no deseadas en la pieza, lo que afectaría su geometría, precisión y calidad estética (Boriwal et al., 2017).



Figura 3. Defectos de RSW.

Aumento de datos

A los datos se les aplica el procesamiento de imágenes “espejo y rotación”, los cuales modifican la relación espacial de una imagen entre sus píxeles. En cuanto a “espejo” ($IMB(i, j)$), refleja o invierte una imagen ($IMA(i, j)$) usando la ecuación 1 (espejo vertical) y ecuación 2 (espejo horizontal) (Gonzalez & Woods, 2017).

$$IMB(i, j) = IMA(N - i, j) \quad (1)$$

$$IMB(i, j) = IMA(i, M - j) \quad (2)$$

Donde: i, j = son las coordenadas de la imagen, N = es el ancho de la imagen, M = es la altura de la imagen.

En cuanto a “rotación”, dado un punto $IMB(i, j)$ se rota θ grados, las coordenadas i' y j' del nuevo punto resultan a partir de la ecuación 3 (Cuevas et al., 2017).

$$\begin{bmatrix} i' \\ j' \end{bmatrix} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \cdot \begin{bmatrix} i \\ j \end{bmatrix} \quad (3)$$

De tal manera que la versión girada de la imagen principal será la mostrada en la ecuación 4.

$$IMB(i', j') = IMB(i \cdot \cos\theta - j \cdot \sin\theta, i \cdot \sin\theta + j \cdot \cos\theta) = IMA(i, j) \quad (4)$$

Donde: θ es el ángulo de rotación que se le aplicará a la imagen.

Al aplicar estas funciones a las imágenes originales de cada clase se tiene la distribución del Cuadro 1.

| Clase | Original | Espejo | Rotación | Total |
|-------------|----------|--------|----------|-------|
| Punto bueno | 19 | 31 | 50 | 100 |
| Punto malo | 17 | 33 | 50 | 100 |
| Doble punto | 34 | 33 | 33 | 100 |

Cuadro 1. Base de datos.

Construcción del clasificador

El clasificador (Figura 4) se construye a partir de una CNN, esta es un tipo de red neuronal profunda diseñada específicamente para tareas relacionadas con el procesamiento de imágenes. Las CNN se destacan en la detección de patrones visuales en datos de entrada, reconocimiento de objetos, clasificación y segmentación de imágenes, entre otros. La característica distintiva de las CNN es su capacidad para realizar convoluciones u operaciones matemáticas que permiten que la red aprenda automáticamente características visuales como bordes, texturas y formas en diferentes regiones de una imagen (Poole & Mackworth, 2017).

La CNN se construyó a partir de las capas: convolución, de agrupación (pooling), y totalmente conectadas. Las capas de convolución aplican filtros para detectar características locales, las capas de agrupación reducen la dimensionalidad de los datos y la capa totalmente conectada se utilizó para obtener la clasificación de las tres clases, “punto bueno”, “punto malo” y “doble punto”.

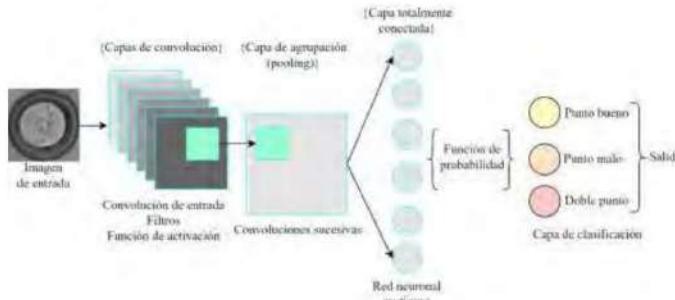


Figura 4. Clasificador con CNN.

Resultados

Evaluación de la CNN

Al ejecutar los experimentos de clasificación de los defectos de la RSW se selecciona un modelo simple de CNN con 8 capas convolucionales con el método de entropía cruzada, de las 3 clases se seleccionan imágenes de entrenamiento, testeo y evaluación como se muestra en el Cuadro 2, una vez seleccionadas las imágenes se procede a verificar la eficiencia de la CNN.

| Clase | Entrenamiento | Testeo | Evaluación | Total |
|-------------|---------------|--------|------------|-------|
| Punto bueno | 60 | 20 | 20 | 100 |
| Punto malo | 60 | 20 | 20 | 100 |
| Doble punto | 60 | 20 | 20 | 100 |

Cuadro 2. Selección de imágenes para la CNN.

Al realizar el entrenamiento, testeo y validación de la CNN, se obtiene una gráfica (Figura 5 a)) que representa la pérdida en función del número de épocas de entrenamiento para un modelo de CNN. La pérdida se utiliza como métrica para evaluar la calidad de la red durante el proceso de entrenamiento. La curva muestra una tendencia descendente a medida que avanzan las épocas. Esto indica que el modelo está mejorando su capacidad para hacer

predicciones a medida que se entrena. La pérdida inicial es alta, pero disminuye conforme avanza el número de épocas. Después de 55 épocas, la pérdida llega a un valor adecuado, esto indica que el modelo converge a una solución óptima.

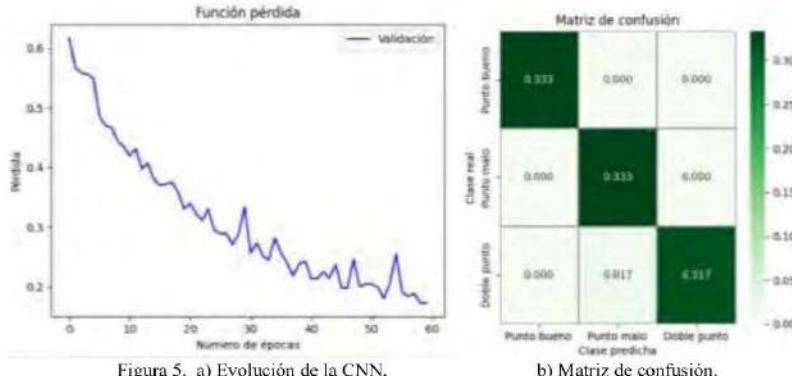


Figura 5. a) Evolución de la CNN,

b) Matriz de confusión.

La matriz de confusión de la Figura 5 b) muestra la clase real y la clase predicha que realizó la CNN. Como se puede observar de la clase “Punto bueno” clasificó correctamente todas las imágenes sin generar falsos positivos de las otras clases, referente al “Punto malo”, supo diferenciar entre las otras dos clases y se clasificaron correctamente las imágenes sin generar una predicción de falso positivo. Pero en la predicción de “Doble punto” generó un falso positivo en la clase “Punto malo”, lo que implica no clasificar correctamente 1 imagen. Al evaluar cada clase de la matriz de confusión se obtuvo una eficiencia del 98.30%.

El cuadro 3 muestra las métricas de la matriz de confusión, la precisión por clase significa: que se calcula individualmente la precisión de cada clase. La sensibilidad de cada clase o tasa de verdaderos positivos: significa la proporción de instancias positivas que fueron correctamente identificadas. La especificidad: es la proporción de instancias negativas que fueron correctamente identificadas. Y finalmente el F1-Score: que combina la precisión y la sensibilidad en una sola clase. Estas métricas muestran el rendimiento de clasificación de la CNN.

Para la clase “Punto bueno”, el modelo logró una precisión y sensibilidad del 100%, indicando que todas las predicciones positivas fueron correctas y que todos los casos reales de “Punto bueno” fueron capturados. La especificidad fue del 97.5%, lo que refleja la capacidad del modelo para predecir los casos negativos de manera efectiva, y el puntaje (F1-Score) alcanzó el 99%, lo que destaca un equilibrio óptimo entre precisión y sensibilidad.

De manera similar, para la clase “Punto malo”, se obtuvieron métricas excepcionales con una precisión y sensibilidad del 100%, una especificidad del 97.4% y un puntaje (F1-Score) del 99%.

La clase “Doble punto” también demostró un sólido rendimiento con una precisión del 94.9%, sensibilidad del 94.3% y especificidad del 100%. El puntaje (F1-Score) para esta clase fue del 96.25%, lo que subraya un equilibrio efectivo entre precisión y sensibilidad.

| Clase | Precisión por clase | Sensibilidad | Especificidad | F1-Score |
|-------------|---------------------|---------------|---------------|---------------|
| Punto bueno | 100% | 100% | 97.50% | 99% |
| Punto malo | 100% | 100% | 97.40% | 99% |
| Doble punto | 94.90% | 94.30% | 100% | 96.25% |
| Total | 98.30% | 98.10% | 98.30% | 98.08% |

Cuadro 3. Métricas de la matriz de confusión.

Discusión

En el Cuadro 4 se muestran los resultados obtenidos de diferentes trabajos para la clasificación de defectos en imágenes de soldadura RSW. Como se puede observar todos los métodos tienen un porcentaje de eficiencia superior al 90%, sin embargo, el método propuesto alcanzó el mayor porcentaje de eficiencia con el 98.3% de clasificación, cabe mencionar que emplearon procesamiento de imágenes para identificar la región de interés (por sus siglas en inglés ROI), a su vez algunos métodos utilizan redes neuronales convolucionales pre-entrenadas y otros métodos para obtener comparativas entre ellas.

| Trabajo | Método | Defectos detectados | Precisión |
|----------------------|-------------------------|---|-----------|
| Dai et al. (2022) | Transfer ResNet- 50+ | Soldadura de borde, Doble punto Pseudosoldaduras, Rebaba Distorsión, Punto flameado, Punto bueno | 97.8% |
| Dai et al. (2021) | Faster R-CNN | Punto bueno, punto malo | 92.04% |
| Presente trabajo | CNN | Punto bueno, Punto malo, Doble punto | 98.3% |

Cuadro 4. Comparativa entre métodos de clasificación de defectos RSW.

Conclusiones

La eficiencia y validez del modelo CNN para la clasificación de defectos de imágenes RSW depende de la cantidad de clases RSW y el número de imágenes de cada clase, al obtener un 98.30% de eficiencia se determina que el modelo tiene un porcentaje de precisión muy alto para la identificación de defectos de soldadura en las tres clases especificadas. Este alto rendimiento sugiere que la CNN es una herramienta adecuada para la detección de defectos de soldaduras por punto en aplicaciones industriales, ya que con este diagnóstico el personal encargado podría tomar acciones que permitan corregir las fallas y a su vez mejorar la calidad y eficiencia del proceso de la soldadura. Sin embargo, es importante evaluar y ajustar el modelo con un mayor número de clases, y un mayor número de imágenes de cada clase, de tal manera que la validez del modelo sea robusta frente a diferentes condiciones y tipos de defectos.

A pesar de los buenos resultados obtenidos, se cuenta con algunas limitaciones, por ejemplo, no contar con una base de datos propia donde exista un número de imágenes alto y un número de clases diverso, el modelo se aplica a una base de datos con tres clases, esto implica que el modelo sea validado solamente para las clases propuestas, esto hace que no se puedan realizar experimentaciones diversas con 4, 5 o 6 clases, de tal manera que se pueda observar la eficiencia al ir aumentando el número de clases. Una extensión de la presente investigación sería incluir otras clases de los defectos RSW y una cantidad más alta de imágenes de cada clase con la finalidad de observar el rendimiento del modelo CNN.

Por otro lado, se recomienda continuar con esta investigación destacando verificar la cantidad y la calidad de los datos de entrenamiento ya que son cruciales para el rendimiento de la CNN. Recopilar una base de datos más grande, incluir otras clases de imágenes RSW. Cuantas más clases de imágenes RSW existan en el conjunto de datos, mayor eficiencia y validez se tendrá en generalizar el modelo como clasificador de defectos de soldadura.

Referencias

- Akkaş, N. (2017). Welding time effect on Tensile-Shear loading in resistance spot welding of SPA-H weathering steel sheets used in railway vehicles. *Acta Physica Polonica A*, 131(1), 52-54. <https://doi.org/10.12693/aphyspola/131.52>
- Alghannam, E., Lu, H., Ma, M., Cheng, Q., González, A., Zang, Y., & Li, S. (2019). A novel method of using vision system and fuzzy logic for quality estimation of resistance spot welding. *Symmetry*, 11(8), 990. <https://doi.org/10.3390/sym11080990>
- Younès, D., Alghannam, E., Tan, Y., & Lü, H. (2020). Enhancement in quality estimation of resistance spot welding using vision system and Fuzzy Support Vector machine. *Symmetry*, 12(8), 1380. <https://doi.org/10.3390/sym12081380>
- Dai, W., Li, D., Ding, T., Jiang, Q., Wang, D., Wang, H., & Peng, Y. (2021). Deep Learning Assisted Vision inspection of resistance spot welds. *Journal of Manufacturing Processes*, 62, 262-274. <https://doi.org/10.1016/j.jmapro.2020.12.015>
- Boriwal, L., Sarviya, R. M., & Mahapatra, M. M. (2017). Failure modes of spot welds in quasi – static tensile – shear loading of coated steel sheets. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.mtpro.2017.02.261>
- Cuevas, E., Cortés, M. D., & Méndez, J. O. C. (2017). Tratamiento de imágenes con MATLAB.
- Dai, W., Li, D., Ding, T., Wang, H., & Peng, Y. (2022). Deep learning approach for defective spot welds classification using small and class-imbalanced datasets. *Neurocomputing*, 477, 46-60. <https://doi.org/10.1016/j.neucom.2022.01.004>
- Duan, R., Luo, Z., Li, Y., Zhang, Y., & Liu, Z. M. (2014). Novel postweld heat treatment method for improving mechanical properties of resistance spot weld. *Science and Technology of Welding and Joining*, 20(2), 100-105. <https://doi.org/10.1179/1362171814y.0000000262>
- Gonzalez, R. C., & Woods, R. E. (2017). *Digital Image Processing*, Global Edition. Pearson Higher Education.
- Hussain, W., Sadiq, M. T., Siuly, S., & Rehman, A. U. (2021). Epileptic seizure detection using 1 d-convolutional long short-term memory neural networks. *Applied Acoustics*, 177, 107941. <https://doi.org/10.1016/j.apacoust.2021.107941>

Podržaj, P., & Simončič, S. (2013). A machine vision-based electrode displacement measurement. *Welding in The World*, 58(1), 93-99.
<https://doi.org/10.1007/s40194-013-0086-7>