



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE MECÁNICA
CARRERA INGENIERÍA AUTOMOTRIZ

**CLASIFICACIÓN DE PIEZAS MECÁNICAS MEDIANTE REDES
NEURONALES ARTIFICIALES**

Trabajo de Integración Curricular

Tipo: Proyecto de Investigación

Presentado para optar al grado académico de:

INGENIERO AUTOMOTRIZ

AUTOR: ESTIVEN DAVID REMACHE PICHUCHO

DIRECTOR: Ing. RODRIGO RIGOBERTO MORENO PALLARES

Riobamba – Ecuador

2023

© 2023, Estiven David Remache Pichucho

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento, siempre y cuando se reconozca el Derecho de Autor.

Yo, Estiven David Remache Pichucho, declaro que el presente Trabajo de Integración Curricular es de mi autoría y los resultados del mismo son auténticos. Los textos en el documento que provienen de otras fuentes están debidamente citados y referenciados.

Como autor asumo la responsabilidad legal y académica de los contenidos de este Trabajo de Integración Curricular; el patrimonio intelectual pertenece a la Escuela Superior Politécnica de Chimborazo.

Riobamba, 19 de diciembre de 2023

A handwritten signature in blue ink that reads "David Remache". The signature is written in a cursive style with a horizontal line underneath the name.

Estiven David Remache Pichucho

1722625181

ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
FACULTAD DE MECÁNICA
CARRERA INGENIERÍA AUTOMOTRIZ

El Tribunal del Trabajo de Integración Curricular certifica que: El Trabajo de Integración Curricular; Tipo: Proyecto de Investigación, **CLASIFICACIÓN DE PIEZAS MECÁNICAS MEDIANTE REDES NEURONALES ARTIFICIALES**, realizado por el señor: **ESTIVEN DAVID REMACHE PICHUCHO**, ha sido minuciosamente revisado por los Miembros del Tribunal del Trabajo de Integración Curricular, el mismo que cumple con los requisitos científicos, técnicos, legales, en tal virtud el Tribunal Autoriza su presentación.

	FIRMA	FECHA
Ing. José Francisco Pérez Fiallos PRESIDENTE DEL TRIBUNAL		2024-01-15
Ing. Rodrigo Rigoberto Moreno Pallares DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR		2024-01-15
Ing. Luis Fernando Buenaño Moyano ASESOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR		2024-01-15

DEDICATORIA

El presente trabajo fruto de mi esfuerzo y dedicación se lo dedico en primer lugar a Dios por permitirme llegar hasta este momento tan importante de mi formación profesional. A mi madre Marina Pichucho por su apoyo incondicional, por haber fundado en mi valores, constancia y dedicación. A mi padre Enrique Remache por ayudarme a elegir mi carrera profesional y guiarme constantemente en la formación de esta. A mis hermanas Karina y Janinne por acompañarme en el trayecto de este importante logro y a Genesis que a pesar de la distancia supo esperar mi regreso.

David

AGRADECIMIENTO

Agradezco a Dios por permitirme tener y disfrutar a mi familia, mostrarme lo hermosa que es la vida y lo justa que puede llegar a ser, a mi familia por darme el apoyo incondicional en cada decisión tomada en el transcurso de mi formación académica y permitirme cumplir un sueño y meta de mi vida, no ha sido sencillo el camino, pero con su afecto y amor he logrado superar todo obstáculo que se me impuso. Les agradezco y hago presente mi gran afecto hacia ustedes, mi hermosa familia.

David

ÍNDICE DE CONTENIDO

ÍNDICE DE TABLAS.....	x
ÍNDICE DE ILUSTRACIONES.....	xi
ÍNDICE DE ANEXOS	xiii
RESUMEN.....	xiv
SUMMARY	xv
INTRODUCCIÓN	1

CAPÍTULO I

1. PROBLEMA DE INVESTIGACIÓN.....	2
1.1. Planteamiento del problema	2
1.2. Limitaciones y delimitaciones.....	2
1.3. Problema general de la investigación.....	2
1.4. Problemas específicos de la investigación.....	2
1.5. Objetivos.....	3
1.5.1. <i>Objetivo general</i>	3
1.5.2. <i>Objetivos específicos</i>	3
1.6. Justificación.....	3
1.6.1. <i>Justificación teórica</i>	3
1.6.2. <i>Justificación metodológica</i>	3
1.6.3. <i>Justificación práctica</i>	4
1.7. Hipótesis	4
1.7.1. <i>Hipótesis del proyecto</i>	4
1.7.2. <i>Hipótesis nula</i>	4

CAPÍTULO II

2. MARCO TEÓRICO.....	5
2.1. Antecedentes de la investigación	5
2.2. Bases teóricas	6
2.2.1. <i>Redes neuronales artificiales</i>	6
2.2.1.1. <i>Introducción a RNA</i>	6
2.2.1.2. <i>Arquitectura de una neurona artificial</i>	7
2.2.1.3. <i>Aplicaciones de RNA</i>	7

2.2.1.4.	<i>RNA Convolutacional. (CNN)</i>	10
2.2.2.	<i>Piezas mecánicas</i>	11
2.2.3.	<i>Imágenes aplicadas para la RNA</i>	12
2.2.4.	<i>RNA con MATLAB</i>	14
2.2.4.1.	<i>Diseño de redes en Matlab</i>	14
2.2.4.2.	<i>Capas de una CNN con MATLAB</i>	15
2.2.4.3.	<i>Métricas de validación de una CNN en MATLAB</i>	16

CAPÍTULO III

3.	MARCO METODOLÓGICO	18
3.1.	Enfoque de la investigación	18
3.2.	Nivel de la investigación	18
3.3.	Diseño de la investigación	19
3.3.1.	<i>Investigación experimental</i>	19
3.3.2.	<i>Investigación transversal</i>	19
3.4.	Tipo de estudio	19
3.4.1.	<i>Investigación documental</i>	19
3.4.2.	<i>Investigación de campo</i>	20
3.5.	Población y tamaño de la muestra	20
3.5.1.	<i>Ubicación geográfica de “Motor Solutions”</i>	21
3.5.2.	<i>Selección de la pieza mecánica con más demanda de venta</i>	21
3.5.3.	<i>Juntas o empaques</i>	22
3.5.3.1.	<i>Juntas metálicas.</i>	23
3.5.4.	<i>Devolución de juntas metálicas</i>	24
3.6.	Organigrama de investigación	25
3.7.	Métodos, técnicas e instrumentos de la investigación	26
3.7.1.	<i>Preproceso para la recolección de imágenes</i>	26
3.7.1.1.	<i>Lugar de recolección de imágenes</i>	26
3.7.1.2.	<i>Calidad de imagen</i>	27
3.7.1.3.	<i>PC para el desarrollo de la investigación</i>	28
3.7.2.	<i>Recolección de imágenes</i>	29
3.7.2.1.	<i>Juntas metálicas con defectos</i>	30
3.7.2.2.	<i>Juntas metálicas sin defectos</i>	31
3.7.3.	<i>Procesamiento de las imágenes</i>	31
3.7.4.	<i>Desarrollo de la CNN</i>	33
3.7.4.1.	<i>Modelo CNN N°1</i>	34

3.7.4.2.	<i>Modelo CNN N°2</i>	35
3.7.5.	<i>Entrenamiento de los modelos de CNN</i>	36
3.7.6.	<i>MATLAB Support Package for USB Webcams</i>	38

CAPÍTULO IV

4.	MARCO DE ANÁLISIS E INTERPRETACIÓN DE RESULTADOS	40
4.1.	Grado de productividad sin CNN	40
4.2.	Matriz de confusión	40
4.2.1.	<i>Evaluación de matriz de confusión CNN N°1</i>	41
4.2.2.	<i>Evaluación de matriz de confusión CNN N°2</i>	42
4.3.	Comparación de los modelos CNN	44
4.4.	Pruebas de entrenamiento con otro PC	45
4.4.1.	<i>Entrenamiento en diferente PC</i>	45
4.4.2.	<i>Matriz de confusión en otro PC</i>	46
4.4.3.	<i>Diferencias de un entrenamiento con otro PC</i>	47
4.5.	Pruebas de funcionamiento	48
4.5.1.	<i>Preprueba de funcionamiento</i>	49
4.5.2.	<i>Prueba final</i>	51
4.6.	Productividad en la clasificación de las juntas metálicas con CNN	52
4.7.	Costo del proyecto de investigación	53

CAPÍTULO V

5.	MARCO PROPOSITIVO	54
----	--------------------------------	----

	CONCLUSIONES	55
--	---------------------------	----

	RECOMENDACIONES	56
--	------------------------------	----

BIBLIOGRAFÍA

ANEXOS

ÍNDICE DE TABLAS

Tabla 3-1:	Devolución de juntas metálicas	25
Tabla 4-1:	Datos de productividad sin aplicar CNN.....	40
Tabla 4-2:	Variables de la matriz de confusión modelo N°1	42
Tabla 4-3:	Variables de la matriz de confusión modelo N°2.....	43
Tabla 4-4:	Comparación de valores de la tabla de confusión	44
Tabla 4-5:	Comparación métrica de Precision.....	44
Tabla 4-6:	Comparación métrica “Accuracy”.....	45
Tabla 4-7:	Valores de la tabla de confusión PC 2.....	47
Tabla 4-8:	Comparación PC1 y PC2.....	47
Tabla 4-9:	Comparación métrica de Presicion.....	48
Tabla 4-10:	Comparación métrica Accuracy	48
Tabla 4-11:	Datos de productividad aplicando CNN.....	52
Tabla 4-12:	Costo de la investigación.....	53

ÍNDICE DE ILUSTRACIONES

Ilustración 2-1:	Diagrama simple de una red neuronal.....	6
Ilustración 2-2:	Capas de una RNA.....	7
Ilustración 2-3:	RNA aplicado al análisis financiero.....	8
Ilustración 2-4:	RNA aplicadas al procesamiento de imágenes.....	8
Ilustración 2-5:	RNA aplicas en diagnóstico.....	9
Ilustración 2-6:	RNA aplicados a control y robótica.....	9
Ilustración 2-7:	RNA aplicadas al procesado de voz.....	10
Ilustración 2-8:	Piezas mecánicas en el vehículo.....	12
Ilustración 2-9:	Características de una imagen.....	14
Ilustración 2-10:	Capa Pooling.....	15
Ilustración 2-11:	Ejemplo de la función SoftMAX.....	16
Ilustración 3-1:	Importaciones de autopartes 2022 vs 2023.....	20
Ilustración 3-2:	Ubicación geográfica.....	21
Ilustración 3-3:	Venta de repuestos primeros 15 días mes de marzo 2022.....	22
Ilustración 3-4:	Venta de repuestos primeros 15 días marzo 2023.....	22
Ilustración 3-5:	Despiece de un MCI.....	23
Ilustración 3-6:	Devolución de juntas metálicas 2022.....	24
Ilustración 3-7:	Organigrama de la investigación.....	25
Ilustración 3-8:	Foco LEDVANCE.....	26
Ilustración 3-9:	Trípode.....	27
Ilustración 3-10:	Verde de fondo.....	27
Ilustración 3-11:	HONOR X8a.....	28
Ilustración 3-12:	Características del PC de la investigación.....	29
Ilustración 3-13:	Inicio de toma de imágenes.....	29
Ilustración 3-14:	Junta metálica defectuosa.....	30
Ilustración 3-15:	Junta metálica sin defectos.....	31
Ilustración 3-16:	IrfanView 64.....	31
Ilustración 3-17:	Carpetas de imágenes sin procesar.....	32
Ilustración 3-18:	Selección de carpetas para el procesado de imágenes.....	32
Ilustración 3-19:	Características de las nuevas imágenes.....	33

Ilustración 3-20:	Carpetas de imágenes ya procesadas.....	33
Ilustración 3-21:	MATLAB R2023a.....	34
Ilustración 3-22:	Arquitectura CNN N°1.....	34
Ilustración 3-23:	Capa de entrada CNN N°1	35
Ilustración 3-24:	Capa intermedia CNN N°1.....	35
Ilustración 3-25:	Capa de salida CNN N°1.....	35
Ilustración 3-26:	Arquitectura de la CNN N°2	36
Ilustración 3-27:	Capa intermedia de la CNN N°2	36
Ilustración 3-28:	Código de entrenamiento CNN N°1.....	37
Ilustración 3-29:	Código de entrenamiento de la CNN N°2.....	37
Ilustración 3-30:	Entrenamiento de la CNN N°1.....	38
Ilustración 3-31:	Entrenamiento de la CNN N°2.....	38
Ilustración 3-32:	MATLAB Support Package for USB Webcams.....	39
Ilustración 3-33:	Código de enlace y clasificación.....	39
Ilustración 3-34:	Clasificación.....	39
Ilustración 4-1:	Matriz de confusión CNN N°1	41
Ilustración 4-2:	Matriz de confusión CNN N°2.....	43
Ilustración 4-3:	Características PC 2	45
Ilustración 4-4:	Entrenamiento Modelo CNN N° 2 PC 2	46
Ilustración 4-5:	Matriz de confusión RN2 PC 2	46
Ilustración 4-6:	Resultado preprueba 1	49
Ilustración 4-7:	Resultado preprueba 2.....	49
Ilustración 4-8:	Resultado preprueba 3.....	50
Ilustración 4-9:	Resultado preprueba 4.....	50
Ilustración 4-10:	Resultado preprueba 5.....	51
Ilustración 4-11:	Resultado preprueba 6.....	51
Ilustración 4-12:	Tolerancia de clasificación.....	52

ÍNDICE DE ANEXOS

ANEXO A: PROCESO DE RECOLECCIÓN DE IMÁGENES DE LA BASE DE DATOS

ANEXO B: BASE DE DATOS DE IMÁGENES

ANEXO C: CÓDIGO DE PROGRAMACIÓN

RESUMEN

Un almacén de repuestos estará expuesto a adquirir piezas mecánicas defectuosas es por lo que se requiere de un sistema automatizado que permita realizar el control de calidad de piezas adquiridas en un almacén de repuestos y lograr reducir la distribución de piezas mecánicas defectuosas, por lo tanto, el objetivo de esta investigación fue desarrollar un programa de clasificación de piezas mecánicas mediante redes neuronales artificiales para lograr una distribución de piezas de calidad a los clientes. La metodología tuvo un enfoque cuantitativo que a base de análisis de datos y tabulación permitió escoger una pieza mecánica para la investigación, un nivel descriptivo que especifica características del elemento con un alcance correlacional que cuantifica, analiza y establece vinculaciones, se aplicó un diseño experimental y transversal con el fin de relacionar las variables en conjunto con su incidencia, siendo imprescindible un estudio documental el cual permitió un desarrollo de redes neuronales artificiales y un estudio de campo que permitió la aplicación de las mismas mediante el software de MATLAB. Por medio de esta metodología se logró aplicar redes neuronales artificiales en la clasificación de piezas mecánicas posteriormente seleccionadas, además se logró mejorar la productividad de un almacén de repuestos automotrices. En esta investigación se concluye que la clasificación de piezas mecánicas mediante redes neuronales artificiales resulta exitosa en un almacén de repuestos y conlleva a mejorar su productividad, con ello se tiene confianza para adquirir las piezas mecánicas para la empresa.

Palabras clave: < REDES NEURONALES >, < MATLAB >, < CONVOLUCIÓN >, < PIEZAS MECÁNICAS >, < CLASIFICACIÓN >.

0035-DBRA-UPT-2024



SUMMARY

A spare parts warehouse will be exposed to acquire defective mechanical parts that is why an automated system is required to perform quality control of parts purchased in a spare parts warehouse and reduce the distribution of defective mechanical parts. Therefore, the research objective was to develop a mechanical parts classification program using artificial neural networks to achieve a distribution of quality parts to customers. The methodology had a quantitative approach that based on data analysis and tabulation allowed choosing a mechanical part for the research. A descriptive level that specifies characteristics of the element and correlational that quantifies, analyzes, and establishes links. An experimental and transversal design was applied to relate the variables together with their incidence, being essential a documentary study which allowed the development of artificial neural networks and a field study that allowed the application of them through MATLAB software. By this methodology it was possible to apply artificial neural networks in the classification of mechanical parts subsequently selected. In addition, the productivity of an automotive parts warehouse was achieved. In this research, it is concluded that the classification of mechanical parts by means of artificial neural networks is successful in a spare parts warehouse and leads to improve its productivity, this provides confidence to acquire mechanical parts for the company.

Keywords: <NEURAL NETWORKS>, <MATLAB>, < CONVOLUTION >, < MECHANICAL PARTS >, < CLASSIFICATION>.



Lic. Sandra Paulina Porrás Pumalema Mgs

C.I. 0603357062

INTRODUCCIÓN

En la actualidad hablar de redes neuronales artificiales puede llegar a ser muy complejo debido al grado de conocimiento que se tiene sobre ellas, sin embargo, su aplicación en la resolución de diferentes problemas cotidianos ha resuelto un sin número de estos mismos problemas ayudando al ser humano a mejorar la eficiencia de su trabajo diario.

Uno de los problemas cotidianos del ser humano es la verificación del buen estado de diferentes piezas automotrices que se distribuyen en gran cantidad, ya que varios almacenes de repuestos que distribuyen piezas mecánicas dependen del mismo para poder satisfacer a los clientes y su entorno en general. Para poder solucionar este tipo de demandas se ha desarrollado las redes neuronales artificiales las cuales clasificarán dichos elementos según sus características y determinarán su estado.

La adquisición de piezas mecánicas en el sector automotriz se repite un sin número de veces debido a esto están expuestos a adquirir piezas mecánicas defectuosas, las redes neuronales nos permiten clasificar dichas piezas mediante la automatización y finalmente distribuir las a diferentes clientes que acuden al almacén de repuestos en búsqueda de dichos elementos.

Las redes neuronales artificiales mediante una base de datos de imágenes son capaces de realizar el procedimiento de selección, ya que se obtiene características de las piezas basándose en algoritmos que permitan decidir el estado de la pieza evaluada y aprobar su calidad, para esto se hace uso de técnicas que se basan en inteligencia artificial.

CAPÍTULO I

1. PROBLEMA DE INVESTIGACIÓN

1.1. Planteamiento del problema

El mercado de importación de repuestos y autopartes en Ecuador alcanzó a junio de 2022 los USD 40 millones, un 12 % más si lo comparamos con 2021, lo que supone alrededor de un crecimiento de USD 26 millones. Las principales importaciones de repuestos y autopartes de automóviles están compuestas por: neumáticos (29 %), sistemas de suspensión (8 %), rastreo satelital (8 %), baterías (7 %), frenos (7 %), ruedas (7), embragues (6 %), sistemas de dirección (4 %), guardabarros (3 %), caja de cambios (2 %) y otros (19 %) (Hoya, 2022, p.5).

El gran crecimiento de importación de repuestos en Ecuador ha traído consigo el aumento de almacenes de repuestos automotrices, la adquisición de piezas mecánicas en gran cantidad requiere un control de calidad ya que un almacén de repuestos estará expuesto a adquirir piezas mecánicas defectuosas es por ello que se requiere de un sistema automatizado que permita realizar el control de calidad de piezas adquiridas en el almacén y lograr reducir la distribución de piezas mecánicas defectuosas.

1.2. Limitaciones y delimitaciones

La cantidad de imágenes que la red neuronal necesita para proceder con la selección de piezas mecánicas es muy amplia esto dependerá para determinar que la visión artificial mejore su eficiencia en la clasificación de piezas mecánicas.

1.3. Problema general de la investigación

¿Es posible automatizar la selección de calidad en piezas mecánicas que son adquiridas en un almacén de repuestos?

1.4. Problemas específicos de la investigación

¿Es posible tener piezas mecánicas de calidad cuando se las adquiere en gran cantidad?

¿Se puede aplicar redes neuronales artificiales en la clasificación de piezas mecánicas?

1.5. Objetivos

1.5.1. Objetivo general

Desarrollar un programa de clasificación de piezas mecánicas mediante redes neuronales artificiales con el fin de aplicarlas al control de calidad para reducir piezas defectuosas durante la adquisición en gran cantidad de dichas piezas por parte de un almacén de repuestos para lograr una distribución de piezas de calidad a los clientes.

1.5.2. Objetivos específicos

- Investigar mediante revisión bibliográfica y literatura científica las aplicaciones del Deep Learning y como esta nueva tecnología puede ser aplicada a la clasificación de piezas mecánicas.
- Seleccionar una pieza mecánica adquirida por un almacén de repuestos que tenga una significativa demanda de venta.
- Entrenar la red neuronal mediante la obtención de imágenes de la pieza mecánica seleccionada.
- Realizar pruebas de funcionamiento de la red neuronal para establecer la efectividad y precisión de proceso.

1.6. Justificación

1.6.1. Justificación teórica

Se pretende aplicar Redes neuronales artificiales para clasificar piezas mecánicas a partir de imágenes con un preproceso que implica buscar características de las piezas mecánicas con el fin de decidir su estado de calidad y con ello brindar seguridad al adquirir piezas mecánicas.

1.6.2. Justificación metodológica

El presente trabajo de investigación se desarrolla tomando en cuenta antecedentes documentales y trabajos prácticos aplicados al control de calidad con los cuales se pretende conocer el desarrollo de redes neuronales artificiales y el trabajo que desempeñan los mismos en la clasificación de piezas mecánicas en la rama automotriz, los cuales nos permiten conocer los puntos de mejora en el sistema de la calidad, ya que con ello se reduciría el número de piezas defectuosas adquiridas por un almacén de repuestos.

1.6.3. Justificación práctica

La gran adquisición de piezas mecánicas demanda su clasificación ya que este procedimiento es muy poco controlado debido al gran número de piezas adquiridas, es por ello por lo que se propone aplicar redes neuronales artificiales mismas que ayudaran en la selección de piezas mecánicas mediante un sistema de automatización y de esta forma mitigar el número de piezas defectuosas adquiridas por un almacén de repuestos automotrices.

1.7. Hipótesis

1.7.1. Hipótesis del proyecto

La aplicación de redes neuronales artificiales en la clasificación de piezas mecánicas mejora la productividad del almacén de repuestos automotrices “Motor Solutions”

1.7.2. Hipótesis nula

La aplicación de redes neuronales artificiales en la clasificación de piezas mecánicas no mejora la productividad del almacén de repuestos automotrices “Motor Solutions”

CAPÍTULO II

2. MARCO TEÓRICO

2.1. Antecedentes de la investigación

En conjunto a lo investigado en la bibliografía acerca de clasificación de piezas mecánicas mediante redes neuronales artificiales se encontró varias investigaciones que detallan la aplicación de redes neuronales artificiales en la clasificación de objetos, que serán el pilar de base para la investigación que se plantea en este proyecto de investigación.

Desarrollo de una Red Neuronal Convolutiva (RNC) con Análisis de Componentes Principales (PCA) y la Red Neuronal Convolutiva sin el Análisis de Componentes Principales para realizar la clasificación de piezas metálicas de acuerdo con su forma geométrica, ya sea regular e irregular. Para la experimentación se utiliza el diseño factorial, con las variables: iluminación, cantidad de neuronas en capa oculta, tipo de optimizador y número de componentes, que permitan obtener al menos el 93% de exactitud. Las piezas metálicas son expuestas a luz fría y cálida a tres niveles de iluminación: 1000 lx, 1500 lx y 2000 lx, establecidos en la Norma Oficial Mexicana NOM-025-STPS-2008. A través del pretratamiento de imágenes con Análisis de Componentes Principales se elimina el ruido que propician los datos redundantes (debido usualmente a la dimensión de los datos) y se obtiene una dimensión menor a la original, esto permite que la Red Neuronal Convolutiva reciba una cantidad menor de datos de entrada (Jiménez, 2022, p.6).

Una red neuronal artificial sí que es capaz de detectar anomalías con una precisión elevada sin ser supervisada por el ser humano. Además, a una velocidad muy elevada. Comprobar para el caso de defectos en latas de refrescos. Con tan sólo 2 horas de entrenamiento, un ordenador es suficientemente potente como para detectar errores con un 97% de precisión, errando en tan sólo 150 imágenes de las 5000 que conforman la base de datos. El objetivo de este trabajo era idear y crear el conjunto de un sistema capaz de detectar defectos en latas de refrescos. Por ello, las principales partes del trabajo han sido la programación de la red y la obtención de la base de datos. Además, en el trabajo también se ha podido ver con perspectiva lo potente que puede llegar a ser la inteligencia artificial en distintas áreas de aplicación (García, 2022, p.3).

Proponer un nuevo sistema de reconocimiento de defectos centrado en la integración de técnicas relevantes en su aplicación; la Función de Frontera de Objetos (BOF) por su rapidez en la segmentación de imágenes, la Red Neuronal Convolutiva (CNN) la cual logra una mayor extracción de características en las imágenes y las Máquinas de Soporte Vectorial (SVM) con la

capacidad de clasificar datos linealmente no separables. Debido a que la extracción profunda de características (CNN) utiliza un mayor procesamiento, se implementa el BOF para reconocer las diferentes piezas elaboradas por una manufactura flexible y la CNN+SVM para el reconocimiento de sus defectos. Se logró un sistema más robusto de detección de defectos en comparación con las técnicas aplicadas por separado en cuanto a la detección de defectos en piezas a través de las imágenes reduciendo el tiempo de procesamiento (Rodríguez, 2018, p.1).

2.2. Bases teóricas

2.2.1. Redes neuronales artificiales

El tema de inteligencia artificial se ha venido analizando desde la década de los cincuenta, aunque las limitaciones tecnológicas en los primeros retrasaron el avance de estudio de estas. En la actualidad, con la rápida progresión del diseño de algoritmos, el crecimiento de conjuntos de datos digitales y el desarrollo de una capacidad computacional, se tiene la posibilidad de ayudar a los humanos en muchas tareas que se vuelven un bucle en sus actividades diarias.

Las Redes Neuronales Artificiales (RNA) son sistemas que imitan el esquema funcional de las neuronas del cerebro humano y tratan de imitar su comportamiento, intentando reproducir el aprendizaje de una red neuronal para realizar una determinada tarea, a través de funciones matemáticas.

2.2.1.1. Introducción a RNA

Una RNA (Red Neuronal Artificial) imita el comportamiento similar a un cerebro humano, con la propiedad de aprender mediante la experiencia. Estos modelos neuronales tienen una estructura esquemática muy parecida al cerebro, tratando de repetirlo mediante simulación su arquitectura se asemeja a una estructura de red biológica. (Cadena & Heredia, 2018, p.6).




Ilustración 2-1: Diagrama simple de una red neuronal

Fuente: (Álvaro, 2019)

Nuestro sistema nervioso se lo puede representar con un sistema de 3 capas como se muestra en la ilustración 1. Se puede representar al cerebro como una red neuronal ya que toma decisiones a partir de estímulos que son convertidos en pulsos eléctricos a través de receptores, el cerebro actúa y emite una respuesta a través de efectores, es decir la neurona es capaz de recibir una señal y enviar una orden.

2.2.1.2. *Arquitectura de una neurona artificial*

Una Red neuronal Artificial tiene como arquitectura una construcción por neuronas interconectadas en varias capas. Los datos ingresan por medio de la capa de entrada, las cuales se transmiten la información a través de una o varias capas ocultas finalmente calculando el resultado en la capa de salida (Cadena & Heredia, 2018, p.7).




Ilustración 2-2: Capas de una RNA

Fuente: (García, 2022)

En la ilustración 2 se muestra que en la entrada de la red neuronal se presenta 3 capas la capa de entrada son variables que deben ingresar como base para que las capas ocultas procesen la información y como resultado entreguen la capa de salida con información procesada con capas de entrada como base del proceso de información.

2.2.1.3. *Aplicaciones de RNA*

Entre las áreas de aplicación de las redes se encuentran entre otras las siguientes: Análisis Financiero; Procesado de Imágenes en el ámbito de la Medicina, Industria y Defensa; Diagnóstico Médico y Comercial; Robótica y Control; Reconocimiento y Síntesis de Voz; Clasificación de Datos provenientes de sensores; Compresión y Codificación de Información.

- Análisis Financiero

Las RNA en comparación de métodos convencionales que se aplican a pronósticos financieros presentan un mejor resultado y mayor confiabilidad en volúmenes de ventas. (Olabe, 2013, p.59).




Ilustración 2-3: RNA aplicado al análisis financiero

Fuente: (Olabe, 2013)

- Procesado de Imágenes

Se aplican en general a la clasificación de objetos a partir de características plasmadas en imágenes y las comparan con el objeto estudiado. (Lubinus; et al., 2021, p.5593).

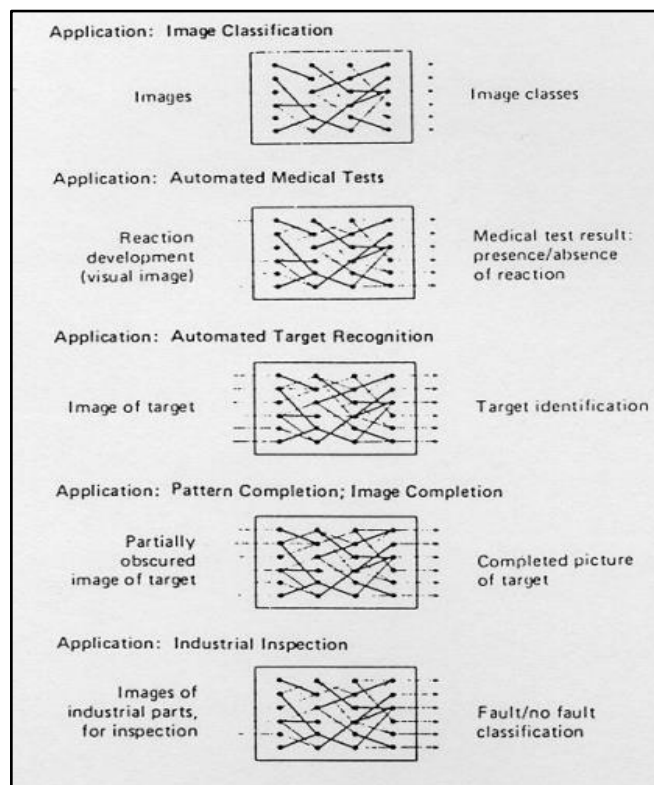


Ilustración 2-4: RNA aplicadas al procesamiento de imágenes

Fuente: (Olabe, 2013)

- Diagnóstico

Mediante lectura de sensores y con una prueba de datos que entregan los sensores se llega a un diagnóstico confiable analizando cada parámetro que nos entrega un sensor. (Álvaro, 2019, p.28).




Ilustración 2-5: RNA aplicas en diagnóstico

Fuente: (Olabe, 2013)

- Control y robótica

Las RNA han sido entrenadas para reproducir o predecir el error que se produce en la posición final de un robot, este error se combina con la posición deseada para proveer la exactitud de la posición final. (Cadena & Heredia, 2018, p.17).




Ilustración 2-6: RNA aplicados a control y robótica

Fuente: (Olabe, 2013)

- Procesado de texto a voz

Tiene la finalidad de partir símbolos gráficos encontrados en un texto convertirlos en un lenguaje hablado, este sistema de computación neuronal fue presentado por Sejnowski y Rosemberg y fue nombrado como NETTALK (Olabe, 2013, p.63).




Ilustración 2-7: RNA aplicadas al procesado de voz

Fuente: (Olabe, 2013)

- Otras aplicaciones

Filtros de ruido, modelación en sistemas, procesado de una señal, Problemas de combinatoria, etc. Son varias aplicaciones y usos que se le da a las redes neuronales artificiales (Olabe, 2013, p.64).

2.2.1.4. RNA Convolutional. (CNN)

La Deep Learning (DL), está enfocada en la investigación profunda que trabaja con algoritmos inspirados en la estructura y funcionamiento del cerebro a través del uso de redes neuronales artificiales que se basa en la estructura y función del cerebro humano, mediante el reconocimiento o categorización de imágenes de los datos distribuidos en múltiples capas compuestas de módulos simples y no lineales, haciendo posible la transformación de los datos para su discriminación. Las redes neuronales convolucionales (CNN, del inglés Convolutional Neural Networks) son el modelo de DL de mayor importancia en la actualidad. (Lubinus & et al., 2021, p.5591).

Las redes neuronales convolucionales que se basan en imágenes son una clasificación entorno a las redes neuronales artificiales utilizadas dentro de la visión artificial. siendo muy útiles para la clasificación y segmentación de imágenes en función de las características, imitan la visión del ser humano, que es capaz de clasificar y diferenciar entre varios objetos, tomando como base las diversas características, como el color, los bordes, las curvas, en general su estructura, es decir, se enfocan en todo aquello que les permite distinguir un objeto del resto, son una clasificación dentro de las redes neuronales artificiales muy utilizadas dentro de la visión artificial. Estas redes son muy útiles para la clasificación y segmentación de imágenes en función del color o las características.

Las CNN se componen por capas: capa de convolución, capa de reducción y capas densas, de las cuales, las dos primeras llevan a cabo una fase de extracción de características, mientras que las últimas son las encargadas de realizar la fase de clasificación. Las primeras capas permiten llevar a cabo una fase de extracción de características que permitirán la clasificación en función de las características tomadas de las imágenes tomadas de entrada.

En la fase de clasificación o también llamada fase de regresión que se realiza en las capas densas se relacionan todas las características ya extraídas y se obtiene directamente una clasificación. Por ejemplo, CNN y se entrena para detectar gatos. La primera fase extrae las principales características de un gato como el pelaje, el color, la forma que tiene el gato. La segunda fase utiliza todas las características extraídas y puede decir si lo que hay en la imagen es un perro o no. Las CNN establecen relaciones entre los diferentes píxeles de una imagen, buscando relaciones en ella, y eso les permite tener un contexto mucho más general con coherencia. Se observa lo que se podría llamar “neurona artificial” y cómo esta trata de seguir la misma arquitectura de una neurona biológica (Lubinus & et al., 2021, p.5592)..

2.2.2. Piezas mecánicas

Se denominan Piezas mecánicas a aquellos elementos que conforman distintos tipos de maquinaria y que cumplen un roll dentro de ella para realizar eficientemente sus funciones, estas piezas son fabricadas mediante procesos tradicionales como:

- Torneado
- Fresado
- Herramientas de corte y abrasión
- Maquinado CNC

Dichos elementos aplicados a la industria automotriz se fabrican con diferentes materiales según requiera el trabajo que la pieza mecánica vaya a realizar, los materiales más usados son:

- Aleaciones de hierro
- Aleaciones de aluminio
- Aleaciones de magnesio

Están formadas por materiales blandos, cumplen la función de sellar la unión de dos piezas evitando fugas y garantizando la hermeticidad entre dichas piezas que comúnmente están expuestas a altas temperaturas y presiones. Por lo general podemos encontrar juntas en un motor de combustión interna (MCI) como por ejemplo la junta entre el cabezote y el colector de escape. Como podemos observar en la imagen se presentan varias juntas en el MCI marcadas de color anaranjado.



Ilustración 2-8: Piezas mecánicas en el vehículo

Fuente: (LOCTITE TEROSON, 2023)

2.2.3. *Imágenes aplicadas para la RNA.*

Las imágenes tomadas como base de datos es un pilar fundamental para CNN ya que la red neuronal debe ser entrenada previamente antes de su aplicación, el número de imágenes que se tenga influye considerablemente en la eficiencia de la red neuronal artificial es decir la cantidad de imágenes es directamente proporcional a la eficiencia de la red neuronal.

Oxford-17 utilizo un conjunto de 1360 imágenes flores de 17 clases diferentes, todas originarias del Reino Unido. Caracterizadas por un gran tamaño, donde la ubicación y la luz varía mucho a

lo largo del conjunto de datos. Existen muchas similitudes entre diferentes clases de flores, como muchas diferencias entre las mismas clases de flores. (Aljure, 2021, p.27).

(Narciso Horna & Manzano Ramos, 2021, p.158) recaudaron un total de 820 imágenes y con ayuda de redes neuronales artificiales seleccionaron arándanos según estándares de exportación, de las cuales se utilizaron 500 centrados a defectos más comunes que se presentan en las empresas agroindustriales de la zona de estudio, como resultado obtuvieron una clasificación considerada.

(Aljure, 2021, p.33) utilizaron redes neuronales artificiales convolucionales y la aplicaron en la selección de flores. Buscó crear un modelo que clasifique de manera eficiente cinco clases de flores (margarita, diente de león, rosa, girasol y tulipán), la base de datos para este estudio cuenta con 3,669 imágenes las cuales se encuentra distribuida para 5 clases de flores.

La red neuronal artificial para poder entrenar adecuadamente a más de cantidad de imágenes necesita que cada imagen tenga una determinada resolución, esto es necesario debido a que por el tamaño y la cantidad de imágenes se alcanzaría un exceso de memoria y la red no sería capaz de entrenar adecuadamente.

(García, 2022, p.22). En la búsqueda de defectos en latas de refresco mediante redes neuronales y visión artificial utilizó imágenes con una resolución de 1467*467 sin embargo esta resolución sería demasiado extensa y la cantidad de imágenes en conjunto con esa resolución englobaría un exceso de memoria y con ello la RNA no podría entrenar, para solucionar este detalle la máxima resolución que la red fue capaz de asimilar es de 300*300 píxeles.

(Aguilar & Campoverde, 2019, p.11) clasificaron frutas mediante RNA convolucionales e infirieron que es importante referir, que dependiendo del tamaño y cantidad de las imágenes (resolución) se obtendrán mejores resultados de aprendizaje, en dicha investigación se implementa imágenes desde 500*500 píxeles.

Para mejorar la calidad de imagen se utiliza filtros que ayuden en la disminución del ruido de la imagen. (Gamarra & Bertel, 2014, p.5) escogieron filtros espaciales, para ello se hizo uso de un filtro adaptativo. Los parámetros de dicho filtro son diferentes para cada pieza, pues, aunque se controlaron las condiciones de iluminación, algunas vistas son más brillantes y tienen un mayor contraste con el fondo. Estos parámetros se seleccionaron a partir de pruebas realizadas a cada vista, escogiendo los que arrojaran mejores resultados en el filtrado.

Las imágenes presentan características las cuales son consideradas importantes dentro de la Visión Artificial para lograr distinguir un determinado objeto de otro ya que todo elemento presenta características diferentes las cuales son propias del mismo y se las puede clasificar acorde a la semejanza de sus características.

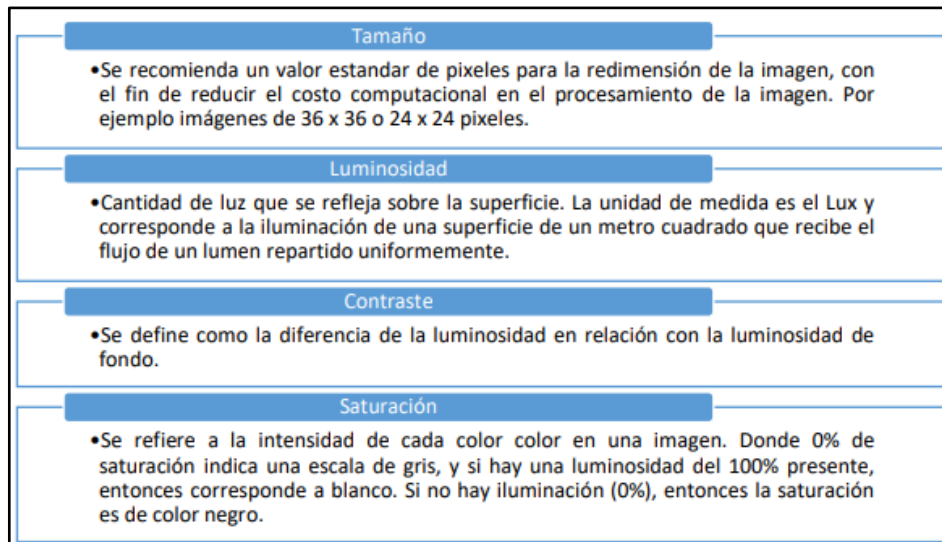


Ilustración 2-9: Características de una imagen

Fuente: (Jiménez, 2022)

2.2.4. RNA con MATLAB

Con herramientas y funciones para administrar grandes conjuntos de datos, MATLAB ofrece "toolboxes" especializadas para trabajar con machine learning, redes neuronales, Deep learning, visión artificial y conducción autónoma (Math Works,2020).

Este software de un alto nivel de aplicaciones es capaz de diseñar redes neuronales artificiales, entrenarlas acorde a su necesidad y aplicarlas en la industria de forma rápida y precisa acorde a la necesidad de su usuario.

2.2.4.1. Diseño de redes en Matlab

El desarrollo de la red implica los siguientes pasos:

1. Acceder al paquete de datos
2. Crear la RNA
3. Establecer la entrada y salida de la red
4. Ajustar los parámetros de la red tales como ponderaciones y tendencias

5. Entrenar a la Red
6. Validar los resultados
7. Integrar la Red en un sistema de producción. (Math Works,2020)

2.2.4.2. Capas de una CNN con MATLAB

- Capa de entrada

Es aquella encargada de recibir los datos del exterior y comunicar esta información a todas las neuronas de la próxima capa.

- Capa de convolución

Según (Chirinos & Calero, 2021, p.11), es muy importante en una CNN, las neuronas de la primera capa convolucional no están conectadas a cada uno de los píxeles de la imagen de entrada, sino solamente a aquellos que se encuentran dentro de su campo receptivo. En la segunda capa convolucional cada neurona está conectada solamente a las neuronas localizadas en un pequeño rectángulo en la primera capa. Esta arquitectura permite que la red se concentre en características de bajo nivel en la primera capa oculta, luego las ensambla en entidades de nivel superior en la siguiente capa oculta, y así sucesivamente.

- Capa Pooling

En esta capa se lleva a cabo un proceso que tiene por objetivo reducir el gasto computacional, obteniendo valores de promedio y de máximo en los datos de entrada como se puede observar en la siguiente ilustración.

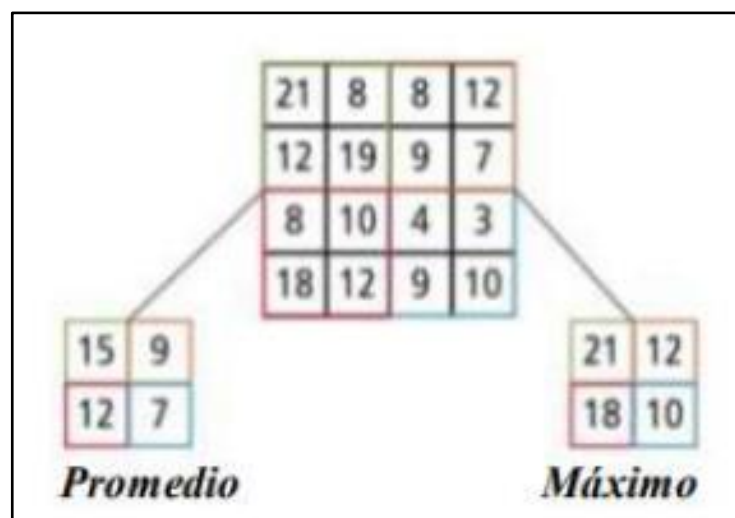


Ilustración 2-10: Capa Pooling

Fuente: (Chirinos & Calero, 2021)

- Capa Full Conected

Tiene la función de vincular a las neuronas ocultas y al ser una capa oculta se denomina feed-forward debido a que la información solo puede tener un sentido de envío, es decir la información no puede volver atrás.

- Capa de salida y función SoftMAX

Según (Chirinos & Calero, 2021, p.12) la capa de salida es una función SoftMAX en la que la salida de cada neurona corresponde a la probabilidad estimada de la clase correspondiente se encarga de medir la evidencia que cada imagen tiene a una clase específica, consiste en realizar una sumatoria de la evidencia pertenecida de cada uno de sus pixeles a esa clase. Visualmente lo podríamos representar como en la siguiente ilustración.




Ilustración 2-11: Ejemplo de la función SoftMAX

Fuente: (Chirinos & Calero, 2021)

2.2.4.3. Métricas de validación de una CNN en MATLAB

- Matriz de confusión

También llamada tabla de contingencia contiene una partición de los ejemplos en función de su clase y predicción, presenta 4 variables: verdadero positivo (TP), falso positivo (FP), falso negativo (FN) y verdadero negativo (TN).

- Accuracy

Se la conoce como exactitud, detalla los ejemplos clasificados con éxito sobre el total de ejemplos. Se la determina mediante la siguiente ecuación.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- Precisión

También conocido como valor predictivo positivo, el cual corresponde a datos positivos ya clasificados sobre el total de datos con predicción positiva, se la obtiene mediante la próxima ecuación.

$$Precision = \frac{TP}{TP + FP}$$

CAPÍTULO III

3. MARCO METODOLÓGICO

3.1. Enfoque de la investigación

El presente trabajo de investigación se fundamentó en el enfoque cuantitativo el cual sustentara la hipótesis planteada de la investigación mediante recolección de datos y análisis de datos con herramientas estadísticas.

En este caso se usó el método deductivo ya que a partir del marco teórico y datos obtenidos obtendremos conclusiones acordes a los objetivos de la investigación en busca de soluciones para el problema de la investigación.

Este enfoque implica la recolección de datos que ayudarán a entrenar la RNA misma que podrá determinar el estado de calidad de una junta metálica en función de una base de imágenes recolectada y que servirá de entrenamiento para la red neuronal en un proceso llevado a cabo en las capas ocultas de la RNA, los datos que se obtienen servirán para determinar la calidad de un numero considerado de piezas metálicas adquiridas por un distribuidor de repuestos automotrices.

3.2. Nivel de la investigación

La investigación presenta un nivel descriptivo el cual busca especificar las características del objeto que se someta a un análisis, es decir, únicamente mide y recoge información de manera independiente de las variables de estudio e indica sobre que se recolectaran estos datos.

Se encuentra el alcance correlacional que asocia las variables mediante un patrón predecible, inicialmente se mide cada una de estas, después se cuantifica, analizan y posteriormente se establecen las vinculaciones (Hernández, 2014, p.93).

Permite la recolección de datos físicos en tiempo real de las juntas metálicas adquiridas por un distribuidor de repuestos automotrices con esta información se relacionan vínculos con la base de datos de imágenes que se encuentran en la capa oculta de la RNA.

3.3. Diseño de la investigación

El diseño conlleva a evidenciar los lineamientos para la solución del problema, conduce a lograr el alcance de los objetivos establecidos en el primer capítulo aplicando estrategias para la recolección de la información, a más de ello permite un análisis autentico aplicado al problema general de la investigación.

3.3.1. Investigación experimental

Recolecta información y obtiene los datos mediante la experimentación, posteriormente compara las variables de estudio considerando que las variables dependientes no se manipulan mientras que las variables independientes pueden variarse en dos o más grados. (Hernández, 2014, p.129).

La aplicación inicia con la recolección de la base de datos de imágenes de juntas metálicas en diferentes aspectos es decir con una clasificación que muestre si son o no defectuosas, a continuación, mediante la RNA se compara dentro de las capas ocultas de la red neuronal entre la base de datos de imágenes y la junta metálica que en ese momento este presente, por último, la RNA determina la calidad de la junta metálica.

3.3.2. Investigación transversal

Permite la recolección de datos en un momento y tiempo único, como objetivos pretende describir las variables, relacionarlas unas con otras en conjunto con su incidencia (Hernández, 2014, p.154). El método de investigación transversal en esta investigación inicia con la recolección de imágenes de juntas metálicas mismas que son clasificadas en una base de datos como defectuosas o no defectuosas acorde a la incidencia de defectos que estas presenten ya se por su proceso de fabricación, almacenaje o transporte hasta el distribuidor de repuestos automotrices.

3.4. Tipo de estudio

3.4.1. Investigación documental

Se la llevo a cabo a través de tesis doctorales e ingenieriles, artículos científicos, y libros los mismos que fueron de sustento y guía en la presente investigación esto conlleva a la confiabilidad de la recopilación de información en esta investigación.

3.4.2. Investigación de campo

Se la realiza con el fin de recolectar una base de datos de imágenes de juntas metálicas en unos almacenes distribuidor de repuestos automotrices, esta base de datos tiene como objetivo lograr el entrenamiento de la RNA misma que será capaz de clasificar juntas metálicas defectuosas o no defectuosas.

3.5. Población y tamaño de la muestra

Un boletín publicado por la Cámara de la Industria Automotriz Ecuatoriana (CINAE) indica que desde marzo 2022 a marzo 2023 las importaciones de autopartes en USD han incrementado significativamente sus cifras, en marzo 2022 el total de importaciones de autopartes en USD fueron de 121050328,06 y en marzo de 2023 el total de importaciones de autopartes en USD fueron 129728764,20 se detalla en la ilustración 3-1.




Ilustración 3-1: Importaciones de autopartes 2022 vs 2023

Fuente: (Cámara de la Industria Automotriz Ecuatoriana, 2023)

Por medio de la Asociación de Empresas Automotrices del Ecuador (AEADE, 2022), se llega a la conclusión que la mayoría de la población ecuatoriana prefieren acudir a un almacén de distribución de repuestos genéricos o alternos, frente a una minoría que muestra una clara preferencia por adquirir repuestos originales o genuinos, dada la tendencia del ecuatoriano

medido a la funcionalidad y a los menores costes y no a la exclusividad. Actualmente, alrededor del 75 % de los recambios son genéricos, mientras que el 25 % son genuinos.

Tomando en consideración lo antes expuesto, la investigación se la realiza en un almacén distribuidor de repuestos genéricos o alternos, almacén que reúne los requisitos necesarios para poder adquirir repuestos automotrices en gran cantidad para próximamente ser distribuidos, con la presente información la investigación se la lleva a cabo en “Motor Solutions”, almacén de repuestos automotrices genéricos ubicado en la ciudad de Latacunga.

3.5.1. Ubicación geográfica de “Motor Solutions”

Se ubica en la provincia de Cotopaxi, cantón Latacunga, entre las calles Av. Marco Aurelio Subía y C. Gatazo, Su propietario Coello Luis.

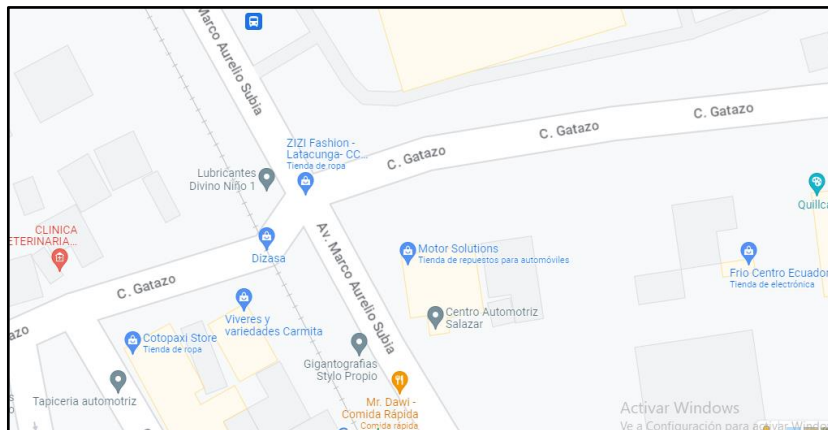


Ilustración 3-2: Ubicación geográfica

Fuente: (GOOGLE MAPS, 2023)

3.5.2. Selección de la pieza mecánica con más demanda de venta

El reporte de ventas de “Motor Solutions” de los primeros 15 días del mes de marzo en 2022 y 2023 refleja que sus ventas de piezas mecánicas han ido incrementando, la ilustración 3-2 y 3-3 refleja la cantidad de repuestos adquiridos por los clientes que frecuentan el almacén de repuestos la primera mitad del mes. En consecuencia, a esta base de datos, la pieza mecánica a ser clasificadas por la red neuronal artificial son las juntas metálicas ya que presentan la mayor salida de ventas, se adquirieron alrededor de 90 juntas metálicas, la primera mitad del mes de marzo 2023.




Ilustración 3-3: Venta de repuestos primeros 15 días mes de marzo 2022

Fuente: (Motor Solutions, 2023)

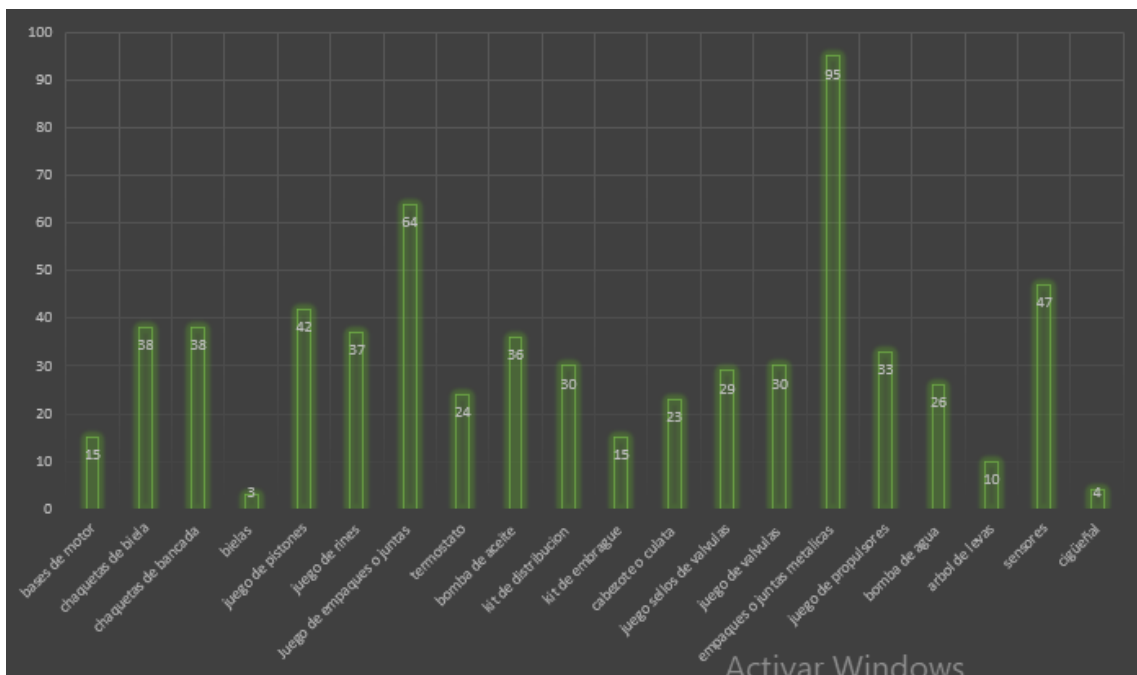


Ilustración 3-4: Venta de repuestos primeros 15 días marzo 2023

Fuente: (Motor Solutions, 2023)

3.5.3. Juntas o empaques

Están formadas por materiales blandos, cumplen la función de sellar la unión de dos piezas evitando fugas y garantizando la hermeticidad entre dichas piezas que comúnmente están expuestas a altas temperaturas y presiones. Por lo general podemos encontrar juntas en un motor de combustión interna (MCI) como por ejemplo la junta entre el cabezote y el colector de escape.

Como podemos observar en la imagen 3-5 se presentan varias juntas en el MCI marcadas de color anaranjado.




Ilustración 3-5: Despiece de un MCI

Fuente: (Cardona, 2016)

3.5.3.1. Juntas metálicas.

Una junta metálica debe soportar altas temperaturas, presión, tensión en la presencia del fluido a ser sellado, en especial debemos considerar lo siguiente:

- Corrosión bajo tensión: los aceros inoxidables 18-8 pueden presentar el fenómeno de la corrosión bajo tensión en presencia de algún fluido. (Veiga, 2003, p.121).
- Corrosión ínter granular: los aceros inoxidables austeníticos, en temperaturas entre 420 °C 810 °C, presentan, en presencia productos químicos, la precipitación de carbonatos entre los granos, fenómeno conocido como corrosión ínter granular en los aceros inoxidables austeníticos. (Veiga, 2003, p.121).
- Compatibilidad con el fluido: la junta debe resistir al deterioro o ataque corrosivo por el fluido, y al mismo tiempo no contaminarlo. (Veiga, 2003, p.121).

Algunos materiales utilizados en la fabricación de juntas metálicas son:

- Acero al carbono
- Acero inoxidable AISI 304
- Acero inoxidable AISI 3041
- Acero inoxidable AISI 316
- Acero inoxidable AISI 316l
- Acero inoxidable AISI 321
- Acero inoxidable AISI 347

3.5.4. Devolución de juntas metálicas

Coello Luis propietario de “Motor Solutions” menciona que la alta demanda de venta que presentan los empaques o juntas metálicas se debe al arduo trabajo que estas llevan a cabo en el vehículo, sin embargo, varias de estas juntas metálicas son devueltas debido a que presentan defectos y para su correcto funcionamiento estas deben estar en óptimas condiciones, estos defectos se producen debido al almacenaje al momento de transportarlos hacia al almacén de repuestos para próximos ser distribuidos, en el último año se han registrado varias devoluciones de dichos elementos y en promedio general de cada 200 juntas metálicas adquiridas 43 son clasificadas como defectuosas.

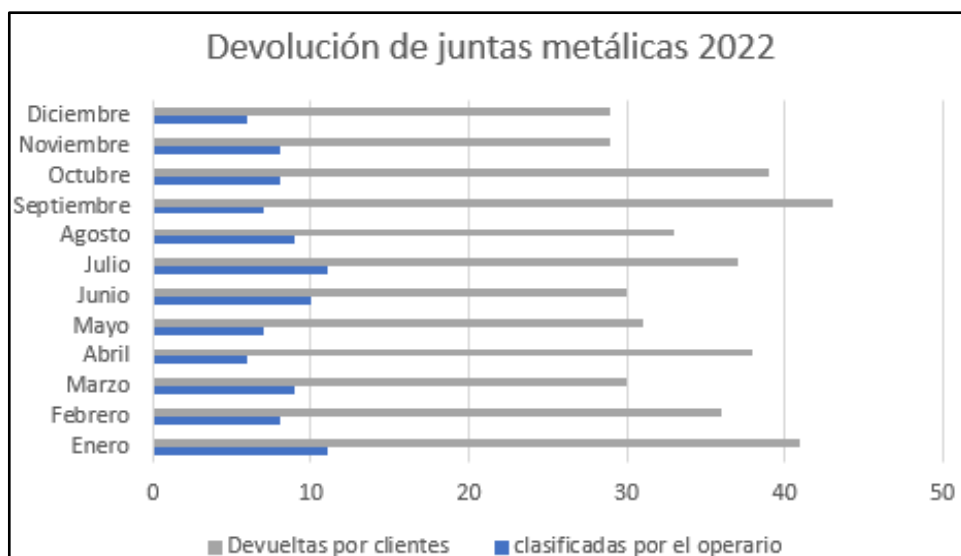


Ilustración 3-6: Devolución de juntas metálicas 2022

Realizado por: Remache. D, 2023.

Tabla 3-1: Devolución de juntas metálicas

Devolución de juntas metálicas 2022			
Meses	Número total adquiridas	clasificadas por el operario	Devueltas por clientes
Enero	200	11	41
Febrero	200	8	36
Marzo	200	9	30
Abril	200	6	38
Mayo	200	7	31
Junio	200	10	30
Julio	200	11	37
Agosto	200	9	33
Septiembre	200	7	43
Octubre	200	8	39
Noviembre	200	8	29
Diciembre	200	6	29
	Promedio	8,33333333	34,6666667
	Total	43	

Fuente: Motor Solution, 2022

Realizado por: Remache. D, 2023.

3.6. Organigrama de investigación

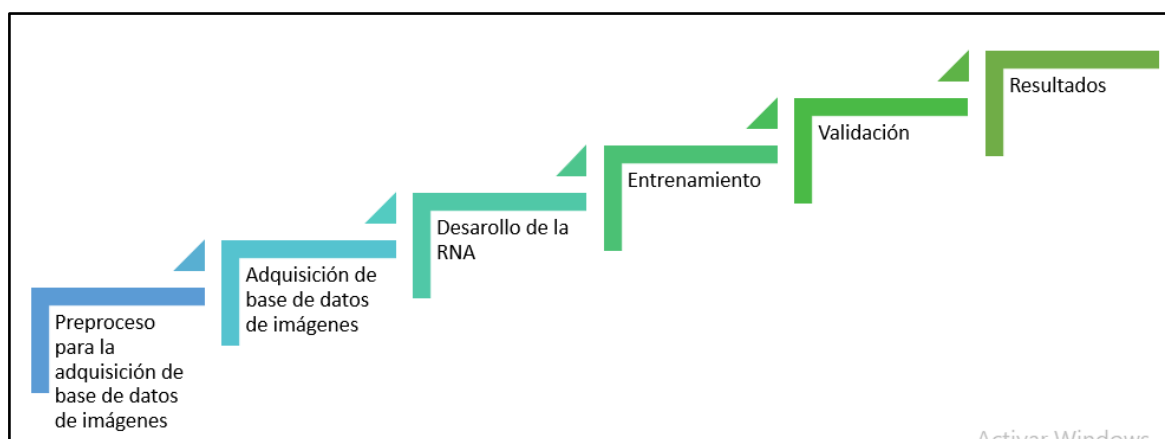


Ilustración 3-7: Organigrama de la investigación

Realizado por: Remache. D, 2023.

3.7. Métodos, técnicas e instrumentos de la investigación

3.7.1. Preproceso para la recolección de imágenes

3.7.1.1. Lugar de recolección de imágenes

Este proceso se lleva a cabo dentro del almacén de repuestos, en la bodega de almacenamiento, para obtener las imágenes que la RNA necesita para realizar la clasificación de piezas mecánicas es necesario acoplar el lugar de obtención de imágenes, identificamos variables que intervengan en el ruido de la imagen:

- Iluminación.

Al encontrarnos en una habitación sin luz solar es más fácil determinar una iluminación adecuada para la toma de imágenes, en este caso se utilizó un foco de alta potencia 40W L/BLANCA LEDVANCE tipo LED presenta una intensidad de 400 lúmenes.



Ilustración 3-8: Foco LEDVANCE

Fuente: (Kywi, 2023)

- Posición de la cámara.

Esta variable es de suma importancia ya que las imágenes deben ser tomadas en una sola posición y a una misma distancia con ello conseguimos que la RNA tenga un entrenamiento más simplificado que le conlleve un menor tiempo a ser entrenada, para ello utilizamos un sistema de empotramiento a la mesa de trabajo es decir la cámara estará en una sola posición capturando imágenes a una misma distancia y posición.



Ilustración 3-9: Trípode

Realizado por: Remache. D, 2023.

- Fondo de imagen.

Se utilizó un fondo verde debido a que este color permite enfocar características netamente de la junta metálica ya que la RNA debe enfocarse a las características del objeto, no a las características de su alrededor.



Ilustración 3-10: Verde de fondo

Realizado por: Remache. D, 2023.

- Posición del objeto de estudio.

Esta variable al igual que la posición de la cámara cumple el mismo objetivo de obtener imágenes en una sola posición para facilitar el entrenamiento de la RNA y que conlleve menos tiempo de entrenamiento.

3.7.1.2. Calidad de imagen

Este parámetro es muy significativo ya que de la calidad de imagen la RNA podrá detectar características que determinen si una junta metálica está o no está en perfectas condiciones,

permitiendo clasificarla como buena o mala, para ello la toma de imágenes se realiza con un dispositivo móvil HONOR X8a, con una pantalla de 6,7 pulgadas, 1080 x 2388 pixeles, RAM 8GB y lo más imprescindible una cámara frontal de 100 MP.




Ilustración 3-11: HONOR X8a

Fuente: HONOR

3.7.1.3. PC para el desarrollo de la investigación

Para el desarrollo completo de la investigación se usó un PC con las características mostradas en la ilustración 3-12

Nombre del dispositivo	DESKTOP-980CBFM
Procesador	AMD Ryzen 5 3500U with Radeon Vega Mobile Gfx 2.10 GHz
RAM instalada	8,00 GB (5,92 GB utilizable)
Id. del dispositivo	BC060416-F2D2-4772-99FC-2C95E8516224
Id. del producto	00331-10000-00001-AA273
Tipo de sistema	Sistema operativo de 64 bits, procesador x64
Lápiz y entrada táctil	La entrada táctil o manuscrita no está disponible para esta pantalla

Copiar

Cambiar el nombre de este equipo

Especificaciones de Windows

Edición	Windows 10 Pro
Versión	22H2
Se instaló el	11/12/2021
Compilación del SO	19045.3086
Experiencia	Windows Feature Experience Pack 1000.19041.1000.0

Ilustración 3-12: Características del PC de la investigación.

Realizado por: Remache. D, 2023.

3.7.2. *Recolección de imágenes*

Se logró obtener imágenes que contribuyan a la clasificación de juntas metálicas mediante el acondicionamiento del lugar de captura de imágenes utilizando todo aquello mencionado anteriormente, se creó un punto fijo de toma de fotografías a una misma iluminación y distancia, tomando en cuenta la calidad de imagen que se requiere para que RNA pueda clasificar las juntas metálicas en defectuosas o no defectuosas.

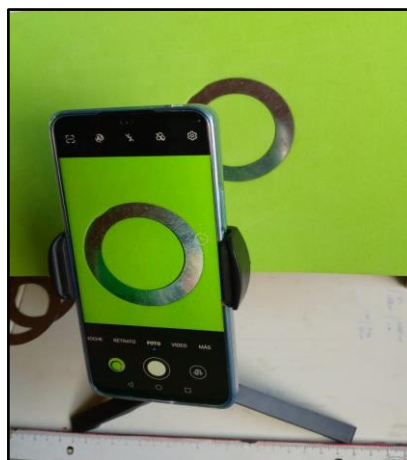


Ilustración 3-13: Inicio de toma de imágenes

Realizado por: Remache. D, 2023.

(Narciso Horna & Manzano Ramos, 2021) en su publicación de sistema de visión artificial basado en redes neuronales convolucionales recaudaron 820 imágenes incluyendo los cinco defectos más comunes que se presentan en las empresas agroindustriales el cual obtuvo un rango de precisiones del 24% al 40,5% para los cinco defectos de arándanos.

(Jiménez, 2022) utilizó un total de 1080 imágenes en su estudio de clasificación de piezas metálicas, a partir de los resultados del diseño factorial se y pruebas con la cámara de 8 MP, el mejor resultado de exactitud correspondió al 83.89 %, el diseño de la factorial favoreció a la exactitud de la RNA a pesar de utilizar una cámara de bajos MP.

(CHIRINOS & CALERO, 2021, p.20) obtuvieron un total de 2923 imágenes tomadas a 30 personas con el uso de la mascarilla para entrenar la RNA que sea capaz de identificar 3 tipos de casos de uso de mascarillas al entrar a un laboratorio (con mascarilla, sin mascarilla, mal uso de mascarilla).

La cantidad y calidad de las imágenes usadas para entrenar la RNA determinará qué tan eficiente será la clasificación de juntas metálicas con los datos históricos de investigaciones anteriores se usó 1100 imágenes para cada grupo, mismas que fueron clasificadas en Juntas metálicas con defectos y juntas metálicas sin defectos.

3.7.2.1. Juntas metálicas con defectos

Para este grupo se definió 1000 imágenes con fallas más comunes encontradas en las juntas metálicas debido al almacenamiento, transporte, fabricación entre otros.



Ilustración 3-14: Junta metálica defectuosa

Realizado por: (Remache. D, 2023)

3.7.2.2. Juntas metálicas sin defectos

De la misma manera se determinó 1000 imágenes de juntas metálicas en buen estado tomando en cuenta que varias presentaban defectos mínimos los cuales sin problema alguno podrían ser distribuidos.




Ilustración 3-15: Junta metálica sin defectos

Realizado por: (Remache. D, 2023)

3.7.3. Procesamiento de las imágenes

El entrenamiento de la RNA no debe ser tan exhausta, para ello se llevó a todas las imágenes a una resolución de 100x75, este proceso se lo realizo con “IrfanView” este software permite llevar a varias imágenes a una misma resolución y a su vez renombrarlas.



Ilustración 3-16: IrfanView 64

Realizado por: (Remache. D, 2023)

El proceso se lo realizó a dos carpetas de la base de datos como muestra la ilustración 3-14, “1” (juntas con defectos) y “2” (juntas sin defectos), renombrando cada una de las imágenes que fue procesada la ilustración 3-15 muestra el proceso de selección de carpeta e imágenes, el nuevo nombre de cada imagen, la extensión del formato de la imagen final y la ubicación de la imagen ya procesada.




Ilustración 3-17: Carpetas de imágenes sin procesar

Realizado por: (Remache. D, 2023)

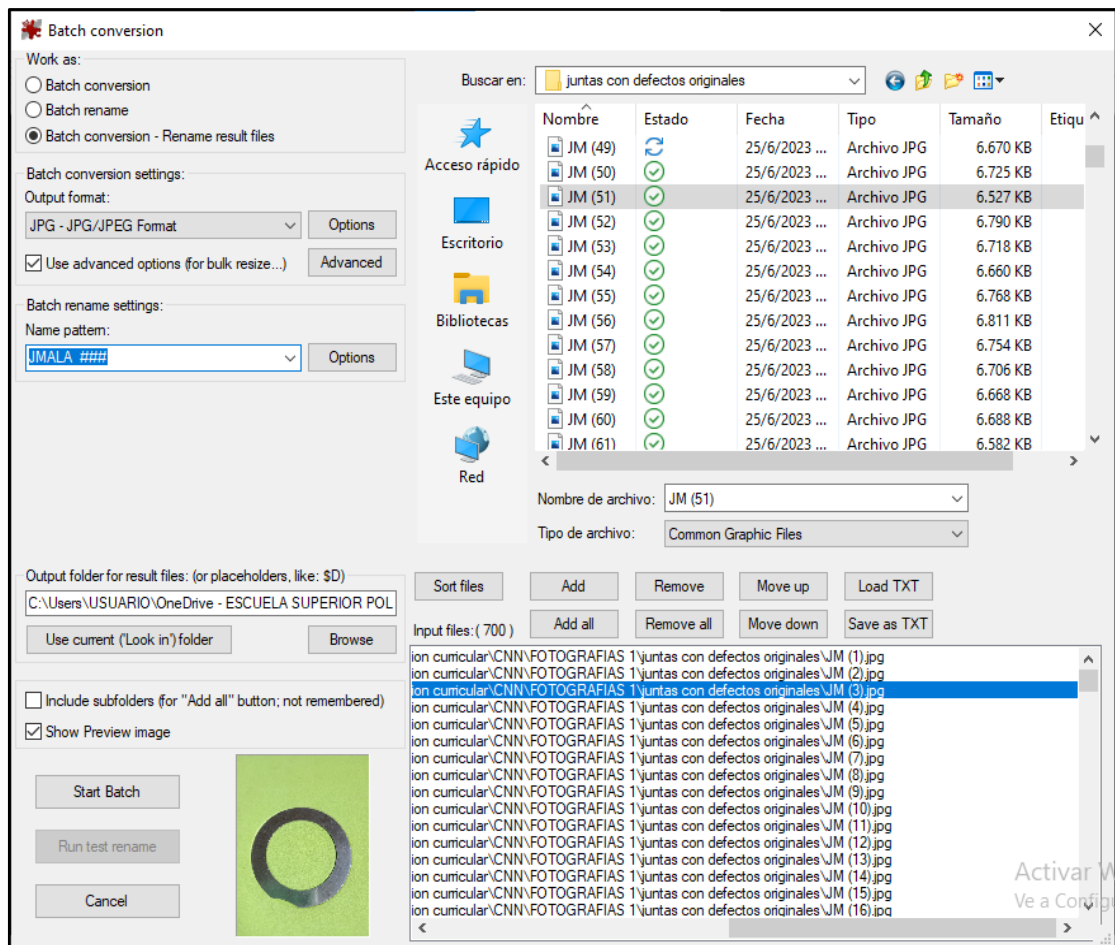


Ilustración 3-18: Selección de carpetas para el procesamiento de imágenes

Realizado por: (Remache. D, 2023)

La ilustración 3-16 muestra la configuración de píxeles que se le dio a las imágenes.

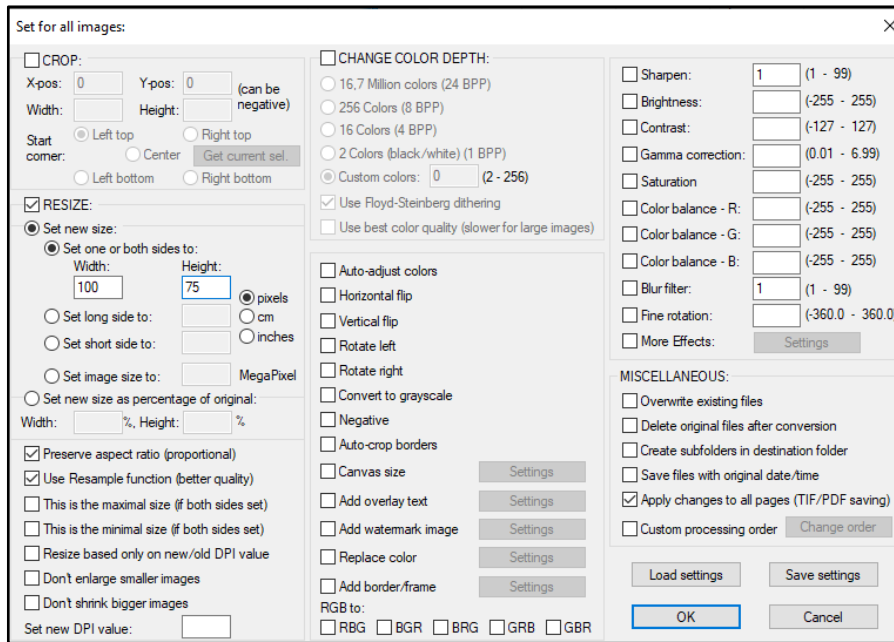


Ilustración 3-19: Características de las nuevas imágenes

Realizado por: (Remache. D, 2023)

Una vez finalizado el proceso de acondicionamiento de imágenes, del mismo se obtuvo dos carpetas de imágenes “defectuosa” y “sin defectos” con las cuales sin problema alguno servirán de entrenamiento a la CNN sin tener un gasto computacional muy elevado.



Ilustración 3-20: Carpetas de imágenes ya procesadas

Realizado por: (Remache. D, 2023)

3.7.4. Desarrollo de la CNN

Para esta investigación se utilizó el software libre MATLAB, esta herramienta de lenguaje de programación de alto nivel es capaz de simplificar el proceso de diseño de una RNA ya que cuenta con herramientas, funciones y comandos que fácilmente pueden administrar gran cantidad de datos y dar lugar al desarrollo de una RNA capaz de ser aplicada en sistemas de empresas según sea su necesidad, la RNA debe cumplir con criterios de evaluación para poder ser aplicada esto dependerá del modo de entrenamiento y el número de imágenes utilizadas para ser más eficiente

y tener un proceso de selección de juntas metálicas exitoso, se creó y entreno dos redes neuronales convolucionales para poder escoger la más eficiente y que el proceso de selección de juntas sea exitoso.



Ilustración 3-21: MATLAB R2023a

Realizado por: (Math Works,2020)

3.7.4.1. Modelo CNN N°1

Para el modelo N°1 se utilizó capas convolucionales, las cuales trabajaron en tres capas de convolución: entrada, intermedia y salida. Para iniciar con la CNN se decidió utilizar 1000 imágenes por cada grupo para el entrenamiento y 100 para la validación detallados en la ilustración 3-19.

```
clear;
clc;
close all;
cat = ["sin defecto","defectuosa"];
rootFolder = "C:\Base de datos";
imds = imageDatastore(fullfile(rootFolder,cat), ...
    "LabelSource","foldernames");
%labelCount = countEachLabel(imds);
img = readimage(imds,1);
%size(img);
numTraingFiles = 1000;
[imdsTrain, imdsValidation] = splitEachLabel(imds,numTraingFiles, "randomize");
```

Ilustración 3-22: Arquitectura CNN N°1

Realizado por: (Remache. D, 2023)

La capa de entrada (imageInputLayer) se la dimensiono con una resolución de 100 x 75 pixeles, esta configuración la muestra la ilustración 3-20. La siguiente capa intermedia se compones de subcapas las cuales aportaran a su respectivo entrenamiento, se definió 3 subcapas mismas que fueron acompañadas con la función de activación ReLu mostrado en la ilustración 3-21, por

último, se adicionó la capa de salida con 3 subcapas: fullyConected, activación Softmax y clasificación. La ilustración 3-22 muestra el diseño.

```
%Capa de entrada
layers = [ ...
    imageInputLayer([100 75 3])
```

Ilustración 3-23: Capa de entrada CNN N°1

Realizado por: (Remache. D, 2023)

```
%Capa intermedia

convolution2dLayer(3,8,"padding","same")
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2, "Stride", 2)

convolution2dLayer(3,16,"padding","same")
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2, "Stride", 2)

convolution2dLayer(3,32,"padding","same")
batchNormalizationLayer
reluLayer
```

Ilustración 3-24: Capa intermedia CNN N°1

Realizado por: (Remache. D, 2023)

```
%Capa de salida

fullyConnectedLayer(2)|
softmaxLayer
classificationLayer];
```

Ilustración 3-25: Capa de salida CNN N°1

Realizado por: (Remache. D, 2023)

3.7.4.2. Modelo CNN N°2

Para el modelo N°2 se utilizó el mismo número de capas convolucionales, se utilizó 1000 imágenes por cada grupo para el entrenamiento y 100 para la validación detallados en la ilustración 3-19.

```

clear;
clc;
close all;
cat = ["sin defecto","defectuosa"];
rootFolder = "C:\Base de datos";
imds = imageDatastore(fullfile(rootFolder,cat), ...
    "LabelSource","foldernames");
%labelCount = countEachLabel(imds);
img = readimage(imds,1);
%size(img);
numTraingFiles = 1000;
[imdsTrain, imdsValidation] = splitEachLabel(imds,numTraingFiles, "randomize");

```

Ilustración 3-26: Arquitectura de la CNN N°2

Realizado por: (Remache. D, 2023)

La capa de entrada y salida de la CNN N°2 tienen la misma configuración que el modelo N°1, para la capa intermedia se adiciono 2 subcapas más quedando un total de 5 subcapas formando la capa intermedia como se muestra en la ilustración 3-24.

```

%Capa intermedia

convolution2dLayer(3,8,"padding","same")
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2, "Stride" , 2)

convolution2dLayer(3,16,"padding","same")
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2, "Stride" , 2)

convolution2dLayer(3,32,"padding","same")
batchNormalizationLayer
reluLayer

maxPooling2dLayer(2, "Stride" , 2)

convolution2dLayer(3,64,"padding","same")
batchNormalizationLayer
reluLayer

convolution2dLayer(3,128,"padding","same")
batchNormalizationLayer
reluLayer

```

Ilustración 3-27: Capa intermedia de la CNN N°2

Realizado por: (Remache. D, 2023)

3.7.5. Entrenamiento de los modelos de CNN

Una vez que fue diseñada la estructura de las CNN (capa de entrada, capa intermedia y capa de salida), se procedió con el entrenamiento de los 2 modelos de CNN, el comando MaxEpoch se asignó con un valor de 3 para CNN N°1, y un valor de 5 para la CNN N°2 esto con el fin de lograr

un entrenamiento eficiente, el código de entrenamiento se detalla a continuación en la ilustración 3-25 y 3-26 respectivamente.

```
options = trainingOptions("sgdm", ...
    "InitialLearnRate",0.01, ...
    "MaxEpochs",3, ...
    "Shuffle","every-epoch", ...
    "ValidationData",imdsValidation, ...
    "ValidationFrequency",30, ...
    "Verbose",false, ...
    "Plots","training-progress");

net = trainNetwork(imdsTrain,layers,options);
YPred = classify(net,imdsValidation);
YValidation = imdsValidation.Labels;
accuracy = sum(YPred == YValidation)/numel(YValidation);
plotconfusion(YValidation,YPred);
```

Ilustración 3-28: Código de entrenamiento CNN N°1

Realizado por: (Remache. D, 2023)

```
options = trainingOptions("sgdm", ...
    "InitialLearnRate",0.01, ...
    "MaxEpochs",5, ...
    "Shuffle","every-epoch", ...
    "ValidationData",imdsValidation, ...
    "ValidationFrequency",30, ...
    "Verbose",false, ...
    "Plots","training-progress");...

net = trainNetwork(imdsTrain,layers,options);
YPred = classify(net,imdsValidation);
YValidation = imdsValidation.Labels;
accuracy = sum(YPred == YValidation)/numel(YValidation);
plotconfusion(YValidation,YPred);
```

Ilustración 3-29: Código de entrenamiento de la CNN N°2

Realizado por: (Remache. D, 2023)

En conjunto de la programación y la ayuda del Toolbox de Matlab, el entrenamiento de los modelos de las CNN fue exitoso la ilustración 3-27 muestra el de entrenamiento de la red neuronal convolucional N°1, la cual como resultado da una validación accuracy de 88,12% en un tiempo de 1 minutos y 6 segundos con 45 iteraciones en el proceso.

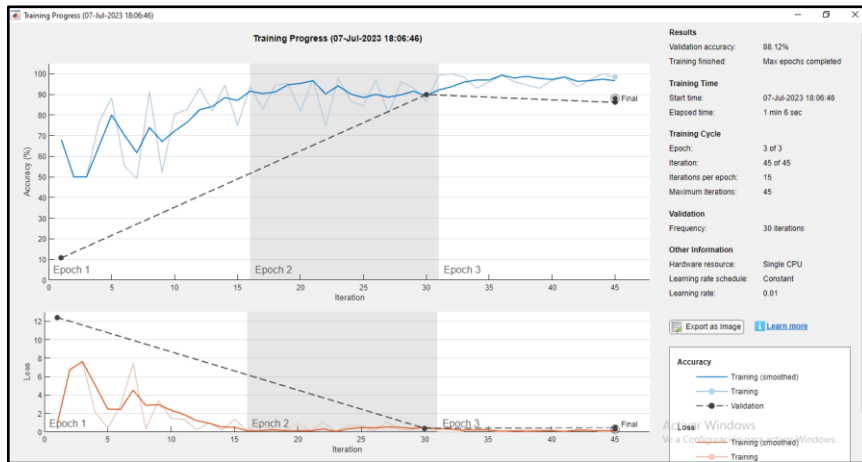


Ilustración 3-30: Entrenamiento de la CNN N°1

Realizado por: (Remache. D, 2023)

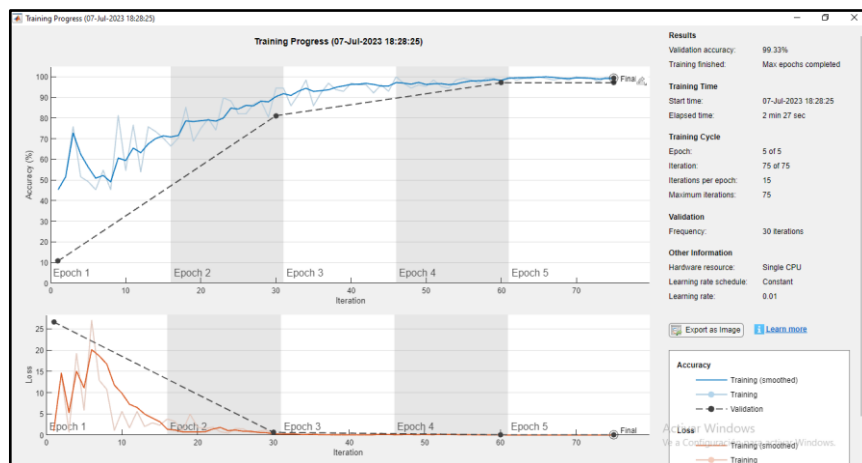


Ilustración 3-31: Entrenamiento de la CNN N°2

Realizado por: (Remache. D, 2023)

La ilustración 3-28 presenta el procesamiento de entrenamiento de la CNN N°2 que se realizó en un tiempo de 2 minutos y 27 segundos, se obtuvo una validation accuracy de 99,33%, con un máximo de iteraciones de 75, en relación con la CNN N°1 se obtuvieron mejores resultados aplicables para investigación, la CNN N°2 será la utilizada para la clasificación de juntas metálicas y a partir de ella se obtendrá el análisis de resultados

3.7.6. *MATLAB Support Package for USB Webcams*

Ya entrenada la red neuronal convolucional lo que resta es aplicar las pruebas de funcionamiento para ello MATLAB necesita de la activación de un complemento para enlazar la CNN y la web cam y de esa manera lograr la clasificación de juntas metálicas, se utilizó el complemento llamado

MATLAB Support Package for USB Webcams para lograr dicho enlace la ilustración 3-29 muestra la activación del complemento en Matlab por medio de Add-On Explorer.



Ilustración 3-32: MATLAB Support Package for USB Webcams

Realizado por: (Math Works,2020)

Una vez que se obtuvo el complemento se procedió con el código de activación y enlace a la red neuronal como se muestra en la ilustración 3-30, el comando “web cam” permite llamar a la cámara utilizada la cual es nombrada como “Iriun”, se crea un bucle con el comando while, la variable “im” es la entrada de la cámara redimensionada mediante “imresize” con un pixelado de 100 x 75, una vez procesada, mediante “classify” la red neuronal actúa para clasificarla este proceso lo hace con el entrenamiento generado posteriormente y toda esta información es la variable net, por ultimo clasifica y detalla en el título de imagen si la junta metálica esta con o sin defectos como se muestra en la ilustración 3-32.

```

camera = webcam("Iriun"); % Connect to the camera
while true
    im = snapshot(camera); % Take a picture
    image(im); % Show the picture
    im = imresize(im,[100 75]); % Resize the picture for squeezeNet
    label = classify(net,im); % Classify the picture
    title(char(label)); % Show the class label
    drawnow
end

```

Ilustración 3-33: Código de enlace y clasificación

Realizado por: (Remache. D, 2023)



Ilustración 3-34: Clasificación

Realizado por: (Remache. D, 2023)

CAPÍTULO IV

4. MARCO DE ANÁLISIS E INTERPRETACIÓN DE RESULTADOS

4.1. Grado de productividad sin CNN

$$Productividad = Eficiencia * Eficacia$$

La tabla 4-1 muestra los datos obtenidos del almacén de repuestos mediante una encuesta realizada al gerente general antes de aplicar las redes neuronales convolucionales, a partir de ella obtuvimos el grado de productividad con la ecuación mostrada anteriormente.

Tabla 4-1: Datos de productividad sin aplicar CNN

CLASIFICACION DE JUNTAS METALICAS		
Personal encargado	1	Personas
Jornada laboral	3	Horas
Horas perdidas en el proceso	1	Horas
Pago diario	25	\$
Gastos diarios	10	\$
Promedio de clasificación	200	Juntas metálicas
Numero de juntas devueltas	43	Juntas metálicas

Fuente: Motor Solution, 2023

Realizado por: Remache. D, 2023.

$$Productividad_{antes} = \left(\frac{3 - 1}{3} * \frac{200 - 43}{200} \right) * 100 = 52\%$$

4.2. Matriz de confusión

En el presente capítulo se reflejan las pruebas y resultados obtenidos en la validación de la Red Neuronal Convolucional (CNN) mediante códigos expuestos en el capítulo anterior para los modelos de las CNN se mostró la matriz de confusión con ayuda del Toolbox de MATLAB con ayuda del comando “plotconfusion(YValidation,YPred)”, donde Yvalidation es la variable de entrada y YPred es la salida que vino a ser el resultado final de la CNN, a continuación se realizan los cálculos de las métricas “ACCURACY y PRECISION” para cada una de las redes neuronales.

4.2.1. Evaluación de matriz de confusión CNN N°1

En la ilustración 4-1 se muestra la matriz de confusión de la red neuronal convolucional teniendo enfoque a las dos salidas que fueron programas, el resultado para “defectuosa” fue de 345 imágenes clasificadas correctamente, esto representa un porcentaje de precisión de 77,4 %, para “sin defecto” fue de 48 imágenes clasificadas de forma correcta representando un porcentaje de 10,9% de precisión. La CNN N°1 de esta investigación logró clasificar correctamente 393 imágenes de un total de 446 imágenes a validar expresado en porcentajes se logró clasificar correctamente el 88,1% y un 11,9% de falsos negativos, falsos positivos y verdaderos negativos en cada caso de evaluación.

Output Class	Target Class		
	defectuosa	sin defecto	
defectuosa	345 77.4%	0 0.0%	100% 0.0%
sin defecto	53 11.9%	48 10.8%	47.5% 52.5%
	86.7% 13.3%	100% 0.0%	88.1% 11.9%

Ilustración 4-1: Matriz de confusión CNN N°1

Realizado por: Remache. D, 2023.

En la siguiente tabla se detallan las variables que se obtuvo a través de la matriz de confusión.

- TP: Verdaderos positivos
- FP: Falsos positivos
- TN: verdaderos negativos
- FN: falsos negativos

Tabla 4-2: Variables de la matriz de confusión modelo N°1

VALOR	TP	FP	TN	FN
Defectuosa	345	0	48	53
sin defecto	48	53	345	0

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

A partir de las ecuaciones mencionadas en el capítulo II, en conjunto con la matriz de confusión que presento las variables TP, FP, TN, FN. Se validó la CNN a través de métricas “Accuracy” y “Precision”, con ayuda de cálculos matemáticos presentados a continuación.

Valor “defectuosa”

$$Accuracy = \frac{345 + 48}{345 + 0 + 48 + 53} = 0.88$$

$$Precision = \frac{345}{345 + 0} = 1$$

Valor “sin defecto”

$$Accuracy = \frac{48 + 345}{345 + 0 + 48 + 53} = 0.88$$

$$Precision = \frac{48}{48 + 53} = 0.47$$

4.2.2. Evaluación de matriz de confusión CNN N°2

Su resultado de “defectuosa” fue de 397 imágenes clasificadas correctamente, esto representa un porcentaje de precisión de 89,0%, para “sin defecto” fue de 46 imágenes clasificadas de forma correcta representando un porcentaje de 10,3% de precisión. Para este modelo se logró clasificar correctamente 443 imágenes de un total de 446 imágenes a validar expresado en porcentajes se logró clasificar correctamente el 99,3% y un 0,7% de falsos negativos, falsos positivos y verdaderos negativos en cada caso de evaluación.




Ilustración 4-2: Matriz de confusión CNN N°2

Realizado por: (Remache. D, 2023)

Tabla 4-3: Variables de la matriz de confusión modelo N°2

VALOR	TP	FP	TN	FN
defectuosa	397	2	46	1
sin defecto	46	1	397	2

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

Valor “defectuosa”

$$Accuracy = \frac{397 + 46}{397 + 2 + 46 + 1} = 0.99$$

$$Precision = \frac{397}{397 + 2} = 0,99$$

Valor “sin defecto”

$$Accuracy = \frac{46 + 397}{46 + 1 + 397 + 2} = 0.99$$

$$Precision = \frac{46}{46 + 1} = 0.98$$

4.3. Comparación de los modelos CNN

La tabla 4-4 presenta la comparación de los valores obtenidos de la matriz de confusión para los dos modelos de CNN, el modelo N°2 tiene mayor cantidad de imágenes clasificadas correctamente (TP o valores positivos), eso muestra que presenta una mejor clasificación de imágenes en relación del primer modelo.

Tabla 4-4: Comparación de valores de la tabla de confusión

CNN	VALOR	TP	FP	TN	FN
N°1	Defectuosa	345	0	48	53
	sin defecto	48	53	345	0
N°2	Defectuosa	397	2	46	1
	sin defecto	46	1	397	2

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

La tabla 4-5 compara la métrica de “Precision” para los dos modelos de CNN, dando como mejor métrica de “Precision” la CNN N°2 en relación con la CNN N°1.

Tabla 4-5: Comparación métrica de Precision

CNN	VALOR	Precision	Promedio total %
N°1	Defectuosa	1	73,5
	sin defecto	0.47	
N°2	Defectuosa	0.99	98,5
	sin defecto	0.98	

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

La tabla 4-6 compara la métrica de “Accuracy” para los dos modelos de CNN, de igual manera dando como mejor evaluación a la métrica “Accuracy” de la CNN N°2.

Tabla 4-6: Comparación métrica “Accuracy”

CNN	VALOR	Accuracy	Promedio total %
N°1	defectuosa	0.88	88
	sin defecto	0.88	
N°2	defectuosa	0.99	99
	sin defecto	0.99	

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

Con las tablas presentadas se determinó que la mejor opción del modelo de CNN es el N°2 ya que presento mejores métricas de evaluación y esta apta para aplicarla en próximas pruebas.

4.4. Pruebas de entrenamiento con otro PC

Esta prueba se la realizo con el fin de comprobar si en otro PC el tiempo de entrenamiento se reducía o a su vez mejoraba su validación “Accuracy”, se utilizó una máquina que sus características se describen en la ilustración 4-3, este dispositivo presenta características diferentes en relación con el PC que se utilizó en todo el desarrollo del proyecto de investigación.



Ilustración 4-3: Características PC 2

Realizado por: (Remache. D, 2023)

4.4.1. Entrenamiento en diferente PC

La comparación se la realizo al modelo CNN N°2 ya que posteriormente presento mejores variables de validación, la ilustración 4-4 muestra el proceso de entrenamiento realizadas en

diferente dispositivo, se puede observar que en un tiempo de 1 minuto y 59 segundos termina su entrenamiento con un máximo de iteraciones de 75 y una validación “Acuuracy” de 99,78.

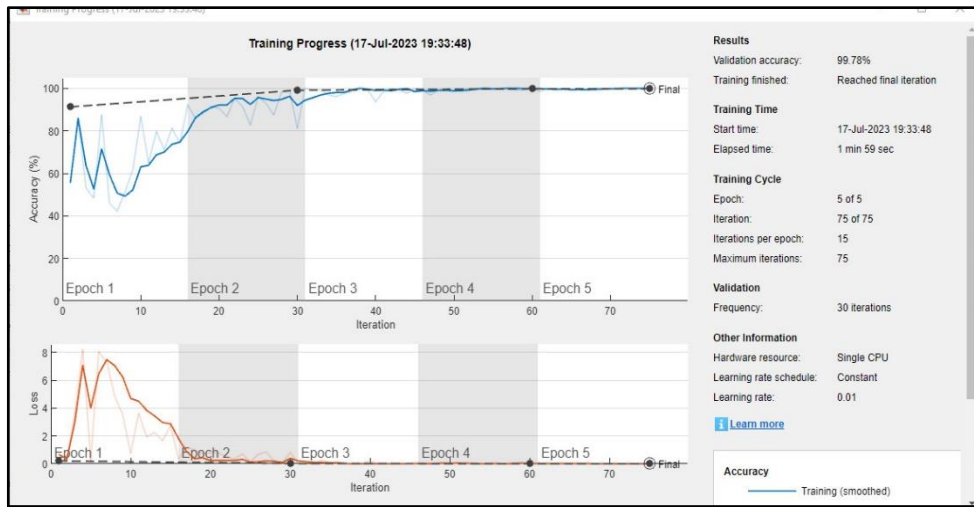


Ilustración 4-4: Entrenamiento Modelo CNN N° 2 PC 2

Realizado por: (Remache. D, 2023)

4.4.2. Matriz de confusión en otro PC

Su resultado de “defectuosa” fue de 398 imágenes clasificadas correctamente, esto representa un porcentaje de precisión de 89,2%, para “sin defecto” fue de 47 imágenes clasificadas de forma correcta representando un porcentaje de 10,5% de precisión. Para este modelo se logró clasificar correctamente 445 imágenes de un total de 446 imágenes a validar expresado en porcentajes se logró clasificar correctamente el 99,8% y un 0,2% de falsos negativos, falsos positivos y verdaderos negativos en cada caso de evaluación.

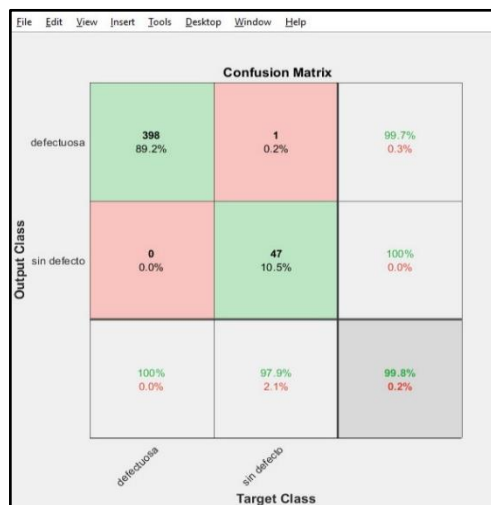


Ilustración 4-5: Matriz de confusión RN2 PC 2

Realizado por: (Remache. D, 2023)

Tabla 4-7: Valores de la tabla de confusión PC 2

CNN	VALOR	TP	FP	TN	FN
PC 2	defectuosa	398	1	47	0
	sin defecto	47	0	398	1

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

Valor “defectuosa”

$$Accuracy = \frac{398 + 47}{398 + 1 + 47 + 0} = 0.997$$

$$Precision = \frac{398}{398 + 1} = 0,997$$

Valor “sin defecto”

$$Accuracy = \frac{47 + 398}{47 + 0 + 398 + 1} = 0.997$$

$$Precision = \frac{47}{47 + 0} = 1$$

4.4.3. Diferencias de un entrenamiento con otro PC

La tabla 4-8 compara las variables de salida de la matriz de confusión en cada caso de entrenamiento llevado a cabo en el modelo N°2 de la CNN, pero en diferentes dispositivos “PC 2” y “PC 1”.

Tabla 4-8: Comparación PC1 y PC2

CNN	VALOR	TP	FP	TN	FN
PC 2	defectuosa	398	1	47	0
	sin defecto	47	0	398	1
PC 1	defectuosa	397	2	46	1
	sin defecto	46	1	397	2

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

Se comparó las variables de validación, se pudo observar que la validación “Precision” en el PC 2 muestra un mejor promedio total en comparación al PC 1, esta mejora varía en un 0,3 % , esta variación no representa un alto grado de mejora, sin embargo se puede observar que el PC 2 desarrolla una mejor ”Precision” al entrenar una red neuronal artificial, la validación “Accuracy” en el PC 2 mostro una diferencia de 0,7 en relación a la variable del PC 1 como se muestra en la tabla 4-9 y 4-10 respectivamente.

Tabla 4-9: Comparación métrica de Precisión

CNN	VALOR	Precisión	Promedio total %
PC 2	defectuosa	0.997	99.8
	sin defecto	1	
PC 1	defectuosa	0.99	98.5
	sin defecto	0.98	

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

Tabla 4-10: Comparación métrica Accuracy

CNN	VALOR	Accuracy	Promedio total
PC 2	defectuosa	0.997	99.7
	sin defecto	0.997	
PC 1	defectuosa	0.99	99
	sin defecto	0.99	

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

El entrenamiento del modelo CNN2 del PC 2 en relación con el PC 1 tuvo mejor eficiencia esto se debió a la diferencia de características de ambos dispositivos, se redujo el tiempo de entrenamiento y se mejoró las variables de validación.

4.5. Pruebas de funcionamiento

Las pruebas de funcionamiento se las realizó en la bodega del almacén “Motor Solutions”. Dentro de la bodega se realizó la instalación de todo el equipo necesario para la clasificación de juntas metálicas, en primer lugar se instaló el módulo de detección que consta de un trípode y la cámara del teléfono móvil (HONOR X8a), mismo que tiene la función de tomar datos en vivo de las juntas metálicas a continuación, se ubicó la laptop (AMD Ryzen 5) y se enlazo con el código de programación de la CNN, por último se procedió a ubicar el fondo (verde) de frente al teléfono móvil para comenzar con la clasificación de las juntas metálicas.

4.5.1. *Preprueba de funcionamiento*

Una vez que se adecuó el lugar de pruebas de funcionamiento, se realizó las pruebas finales para la clasificación de “juntas metálicas en “defectuosas o “sin defecto”. Se dio inicio con juntas metálicas que previamente se utilizaron para formar la base de datos de imágenes para el entrenamiento de la red neuronal, es decir, ya se determinó juntas con y sin defectos. En primer lugar, se realizó una preprueba a juntas metálicas con defectos.




Ilustración 4-6: Resultado preprueba 1

Realizado por: (Remache. D, 2023)




Ilustración 4-7: Resultado preprueba 2

Realizado por: (Remache. D, 2023)

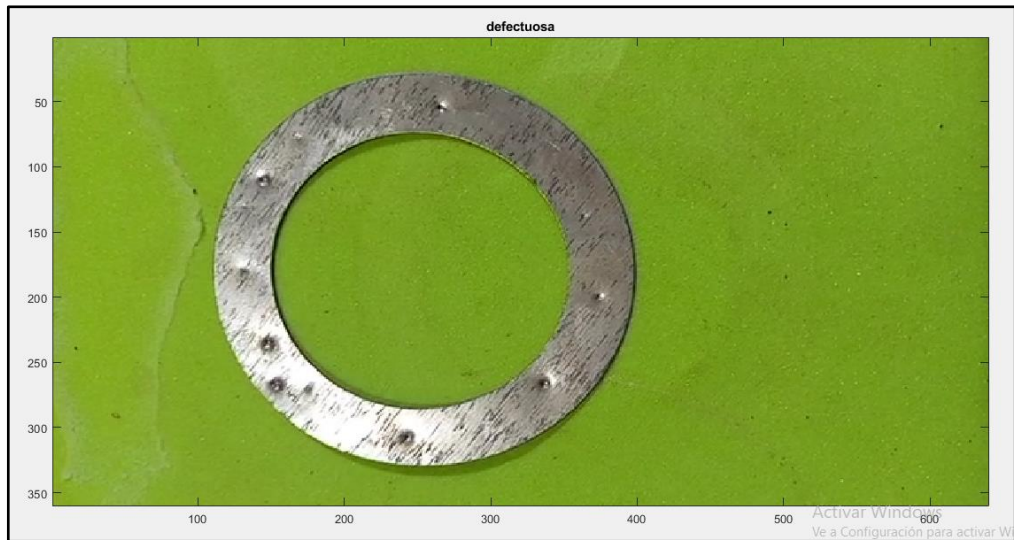


Ilustración 4-8: Resultado preprueba 3

Realizado por: (Remache. D, 2023)

La CNN clasifico correctamente las juntas metálicas defectuosas, a continuación, se realizó la prueba con las juntas metálicas sin defectos tomando en cuenta la misma métrica que se tuvo para la preprueba de juntas metálicas con defectos.




Ilustración 4-9: Resultado preprueba 4

Realizado por: (Remache. D, 2023)




Ilustración 4-10: Resultado preprueba 5

Realizado por: (Remache. D, 2023)



Ilustración 4-11: Resultado preprueba 6

Realizado por: (Remache. D, 2023)

4.5.2. Prueba final

Para la prueba final se utilizó un lote de 200 juntas metálicas adquiridas recientemente por el almacén de repuestos “Motor Solutions”, de las 200 juntas clasificadas se observó que 10 de ellas se clasificaron incorrectamente el software las catalogo como sin defectos sin embargo presentaban un pequeño defecto esto se debe a la tolerancia de defectos que se mantuvo en el entrenamiento de la CNN, esas juntas que fueron clasificadas con esa tolerancia podrán ser utilizadas sin problema alguno, la ilustración 4-12 muestra la junta con la tolerancia de defecto.

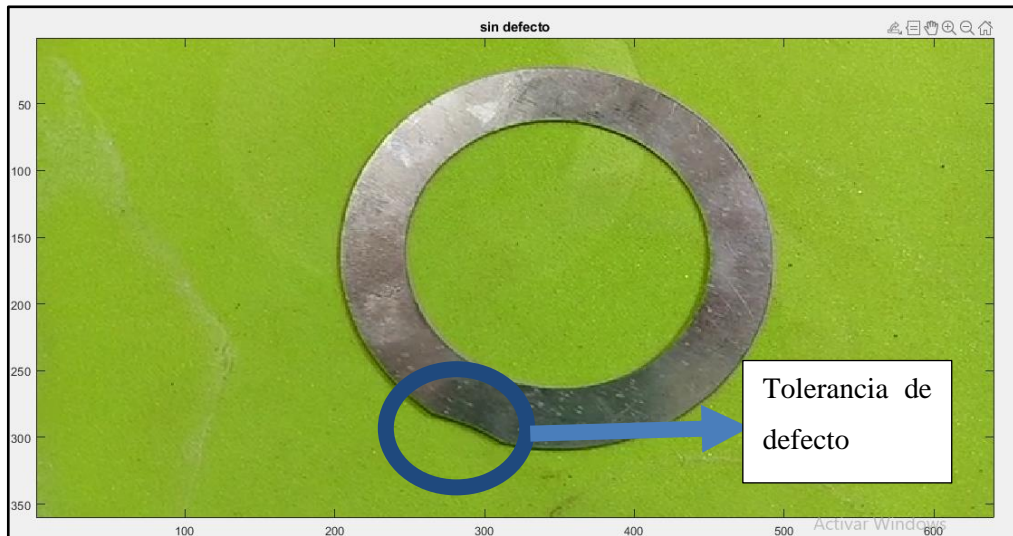


Ilustración 4-12: Tolerancia de clasificación

Realizado por: (Remache. D, 2023)

4.6. Productividad en la clasificación de las juntas metálicas con CNN

Una vez aplicada la red neuronal convolucional se pudo clasificar 200 juntas metálicas en un tiempo de 1 hora, sin embargo, parte de este tiempo se usó para instalar los equipos necesarios y cargar el software, esto represento una pérdida de tiempo del 15% del tiempo total, y se notó que de cada 200 juntas clasificadas 10 de ellas resultaban estar mal clasificadas, los datos se los toma en tiempo real, tal como muestra la tabla 4-2.

Tabla 4-11: Datos de productividad aplicando CNN

CLASIFICACION DE JUNTAS METALICAS		
Personal encargado	1	Software
Tiempo empleado	1	Horas
Horas perdidas en el proceso	0.15	Horas
Promedio de clasificación	200	Juntas metálicas
Numero de juntas devueltas	10	Juntas metálicas

Fuente: Motor Solution, 2023

Realizado por: (Remache. D, 2023)

$$Productividad_{despues} = \left(\frac{1 - 0,15}{1} * \frac{200 - 10}{200} \right) * 100 = 81\%$$

Como se pudo observar en el grado de productividad antes y después se determinó que aplicar redes neuronales convolucionales a la clasificación de juntas metálicas es muy factible, se reduce

el tiempo de clasificación y esto conlleva a una mejor confianza al expender el producto, evitando devoluciones y disgusto en clientes que a menudo frecuentan el almacén de repuestos.

4.7. Costo del proyecto de investigación

Tabla 4-12: Costo de la investigación

Costo del proyecto de investigación			
Descripción	Cantidad	Costo unitario \$	Costo total \$
Teléfono móvil Honor X8a	1	240	240
software IrfanView	1	0	0
Software Matlab	1	0	0
Complementos Add-On	1	0	0
Laptop	1	0	0
Trípode para el teléfono móvil	1	10	10
Varios		40	40
Total			290

Fuente: (Remache. D, 2023)

Realizado por: (Remache. D, 2023)

CAPÍTULO V

5. MARCO PROPOSITIVO

En esta investigación se utilizó redes neuronales convolucionales (CNN) para lograr la clasificación del estado de juntas metálicas, de esta forma mejorar la productividad en el control de calidad del producto que adquiere el almacén de repuestos automotrices “Motor Solutions”, se propone realizar la aplicación de la red neuronal artificial en diferentes piezas mecánicas con la misma arquitectura de la CNN N°2, comprobar su entrenamiento y verificar la mejora de la productividad al momento de adquirir elementos mecánicos en el almacén de repuestos.

Para poder aplicar la CNN N° 2 en otro elemento mecánico es necesario sustituir las imágenes de la base de datos por imágenes del nuevo elemento de estudio, mostrando los posibles defectos que dicho elemento pueda tener y las diferentes características que presenta el elemento de estudio, una vez entrenada la CNN, proceder con la validación de su entrenamiento para posteriormente aplicarla en el almacén de repuestos y verificar su productividad al adquirir piezas mecánicas, corroborar que la aplicación de redes neuronales artificiales en la industria contribuye a la mejora de la productividad en distintos almacenes de repuestos automotrices.

CONCLUSIONES

- Las RNA convolucionales pueden ser aplicadas en la clasificación de piezas mecánicas, extrayendo sus características a través de imágenes que posteriormente servirán de base de datos para la RNA.
- De la gran variedad de repuestos se seleccionó juntas metálicas ya que presentan mayor demanda en ventas, por medio de datos históricos se determinó que, al adquirir 200 juntas metálicas mensuales en el año 2022, un total de 43 de ellas resultó defectuosas.
- Se utilizó 1000 imágenes para cada grupo de estudio y fueron utilizadas para el entrenamiento de la RNA con el fin de que su aplicación sea exitosa.
- Se utilizó la RNA N°2 por presentar un 99% en sus métricas de “Precision” y “Accuracy”
- Se realizó 2 pruebas de funcionamiento, la primera con juntas metálicas que sirvieron para obtener la base de datos dando como resultado una clasificación 100% exitosa, para la segunda prueba se utilizó un lote de 200 juntas de las cuales 10 de ellas catalogadas como sin defectos tenían un minucioso defecto, esto representa la tolerancia de defectos que se tuvo en la base de datos estas juntas pueden ser distribuidas sin problema alguno, sin embargo se puede concluir que de cada 200 juntas clasificadas el 5% resulta ser un error en la clasificación.
- La productividad del almacén en que los últimos años se ha venido trabajando es del 52%, la aplicación de redes neuronales artificiales mejoro esta variable de clasificación es del 81% de la productividad.

RECOMENDACIONES

- Se recomienda tener una base de datos de imágenes que tengan la misma resolución y a su vez estos no sean mayores a 100 píxeles debido que esto supone mayor tiempo de entrenamiento y mayor gasto computacional.
- Es imprescindible tener conocimientos básicos del uso de software MATLAB ya que el código depende de la necesidad de aplicación.
- El gasto computacional requiere una computadora capaz de trabajar sin problema con el software MATLAB.
- El software Matlab para poder trabajar con CNN necesita de complementos, se recomienda tener la licencia original.

BIBLIOGRAFÍA

AGUILAR, V & CAMPOVERDE, M. “Clasificación de frutas basadas en redes neuronales convolucionales”. *Clasificación de frutas basadas en redes neuronales convolucionales*. [En línea], 2019, vol. 5 (1), págs. 3–22. [Consulta: marzo 2023]. ISSN 2550 - 682X. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=7436055>

ALJURE, Y. Clasificación de Flores con Redes Neuronales Convolucionales. [En línea]. (Trabajo de grado) (Especialización). Universidad de Antioquia. Colombia. 2021. Págs. 33-45. [Consulta: marzo 2023]. Disponible en: https://bibliotecadigital.udea.edu.co/bitstream/10495/24683/1/AljureYalila_2021_ClasificacionImagenesFlores.pdf

ÁLVARO, A. Clasificación de imágenes usando redes neuronales convolucionales en Python. [En línea]. (Trabajo de grado) (Ingeniería). Universidad de Sevilla. Departamento de Teoría de la Señal y Comunicaciones. Sevilla. 2019. Págs. 40-53. [Consulta: marzo 2023]. Disponible en: <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1&isAllowed=y>

CADENA, L & HEREDIA, J. Sistema inteligente con visión artificial para el reconocimiento de piezas mecánicas en el robot NAO. [En línea]. (Trabajo de grado) (Ingeniería). Universidad Politécnica Salesiana. Ecuador. 2018. Págs. 6-17. [Consulta: marzo 2023]. Disponible en: <http://dspace.ups.edu.ec/handle/123456789/15012>

CÁMARA DE LA INDUSTRIA AUTOMOTRIZ ECUATORIANA, CIAE. Boletín Estadístico y Autopartes. [En línea]. [Consulta: marzo 2023]. Disponible en: <https://www.cinae.org.ec/>

CHIRINOS, X., & CALERO, P. Detección del uso correcto de mascarillas utilizando una red neuronal convolucional para el ingreso de personas a un laboratorio de una universidad. [En línea]. (Trabajo de grado) (Ingeniería). Universidad Ricardo Palma. 2021. Págs. 50-80. [Consulta: marzo 2023]. Disponible en: <https://hdl.handle.net/20.500.14138/4918>

GAMARRA, M & BERTEL, F. “Clasificación De Piezas Metalmecánicas Basado En Algoritmos Inteligentes Implementando Procesamiento Digital De Imágenes”. *Clasificación De Piezas Metalmecánicas Basado En Algoritmos Inteligentes Implementando Procesamiento Digital De Imágenes*. [En línea], 2014, págs. 3–5. [Consulta: marzo 2023]. Disponible en:

https://www.academia.edu/68527796/Clasificaci%C3%B3n_De_Piezas_Metalmec%C3%A1nicas_Basado_En_Algoritmos_Inteligentes_Implementando_Procesamiento_Digital_De_Im%C3%A1genes

GARCÍA, P. P. Detección de defectos en latas de refrescos mediante redes neuronales y visión artificial. [En línea]. (Trabajo de grado) (Ingeniería). Escuela Técnica Superior de Ingeniería industrial de Barcelona. 2022. págs. 3-22. [Consulta: marzo 2023]. Disponible en: <https://upcommons.upc.edu/handle/2117/371689>

HERNÁNDEZ, R. Metodología de la investigación. 6. México: 2014, págs.21-154.

HOYA, A. ICEX. El mercado de repuestos y autopartes en Ecuador. [En línea]. [Consulta: marzo 2022]. Disponible en: <https://www.icex.es/content/dam/es/icex/oficinas/096/documentos/2022/10/documentos-anexos/DOC2022915769.pdf>

JIMÉNEZ, M. M. Clasificación de piezas metálicas mediante una Red Neuronal Convolutiva y Análisis de Componentes Principales. [En línea]. (Trabajo de grado) (Ingeniería). Universidad Autónoma Del Estado De México.2022. pág. 6. [Consulta: marzo 2023]. Disponible en: <http://hdl.handle.net/20.500.11799/137394>

LUBINUS, B., et al. “Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas”. *Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas*. [En línea], 2021, págs. 5591–5600. [Consulta: marzo 2023]. Disponible en: <https://doi.org/10.53903/01212095.161>

NARCISO HORNA, W. A., & MANZANO RAMOS, E. A. “Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos según estándares de exportación”. Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos según estándares de exportación. [En línea], 2021, págs. 155–166. [Consulta: marzo 2023]. Disponible en: <https://www.usmp.edu.pe/campus/pdf/revista32/articulo1.pdf>

OLABE, X. B. *Redes neuronales artificiales y sus aplicaciones*. [En línea]. Escuela Superior de Ingeniería de Bilbao, EHU, 2016. [Consulta: marzo 2023]. Disponible en: https://ocw.ehu.es/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf

RODRÍGUEZ, Y. B. Integración de la red neuronal convolucional con el algoritmo de función de frontera de objeto para reconocimiento de piezas y detección de defectos. [En línea]. (Trabajo de grado) (Maestría). CORPORACIÓN MEXICANA DE INVESTIGACIÓN EN MATERIALES. 2022. págs. 19-25. [Consulta: marzo 2023]. Disponible en: https://comimsa.repositorioinstitucional.mx/jspui/bitstream/1022/322/1/Tesis%20de%20Maestr%C3%ADa_%20Yanier%20_Basulto%20Rodr%C3%ADguez.pdf

VEIGA, J. CARLOS. “Juntas industriales “. *Juntas industriales*. [En línea], 2003, vol. 1, p. 3–22. [Consulta: marzo 2023]. ISSN 2550 - 682X. Disponible en: https://teadit.com/wp-content/uploads/2021/08/1573473170_Livro-Juntas-Industriales-2.pdf



ANEXOS

ANEXO A: PROCESO DE RECOLECCION DE IMÁGENES DE LA BASE DE DATOS.



ANEXO B: BASE DE DATOS DE IMÁGENES.

[BASE DE DATOS](#)



ANEXO C: CÓDIGO DE PROGRAMACIÓN.

[CÓDIGO DE PROGRAMACIÓN](#)



ESCUELA SUPERIOR POLITÉCNICA DE CHIMBORAZO
CERTIFICADO DE CUMPLIMIENTO DE LA GUÍA PARA
NORMALIZACIÓN DE TRABAJOS DE FIN DE GRADO

Fecha de entrega: 03/01/2024

INFORMACIÓN DEL AUTOR
Estiven David Remache Pichucho
INFORMACIÓN INSTITUCIONAL
Facultad: Mecánica
Carrera: Ingeniería Automotriz
Título para optar: Ingeniero Automotriz
 Director del Trabajo de Integración Curricular Ing. Rodrigo Rigoberto Moreno Pallares  Asesor del Trabajo de Integración Curricular Ing. Luis Fernando Buenaño Moyano