

UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN



**Sistema inteligente basado en el reconocimiento de imágenes para la
clasificación de discos de aluminio en una empresa fundidora en Chiclayo**

**TESIS PARA OPTAR POR EL TÍTULO DE
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

AUTOR

Jhon Emerson Damian Flores

ASESOR

Juan Antonio Torres Benavides

<https://orcid.org/0000-0002-0133-119X>

Chiclayo, 2025

**Sistema inteligente basado en el reconocimiento de imágenes para la
clasificación de discos de aluminio en una empresa fundidora en
Chiclayo**

PRESENTADA POR
Jhon Emerson Damian Flores

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR

William Alfredo Noblecilla Vences
PRESIDENTE

Jury Yesenia Aquino Trujillo
SECRETARIO

Juan Antonio Torres Benavides
VOCAL

Dedicatoria

A Dios, por darme la fuerza y la sabiduría necesarias para superar los desafíos en cada etapa de mi vida. Sin su guía, este logro no habría sido posible. A mis padres y hermanos, por brindarme su apoyo incondicional a lo largo de mi carrera profesional y ser los motores de inspiración en la vida. A mis abuelos, por sus enseñanzas y siempre mostrarme lo valioso de la vida. Finalmente, a mis amigos, por su amistad y por ser un respaldo importante a lo largo de mi camino. A todos ellos, dedico este esfuerzo con todo mi agradecimiento.

Agradecimientos

A mi asesor de tesis el Ingeniero Juan Torres Benavides, por el interés y enseñanzas brindadas a lo largo del desarrollo de mi investigación y de mi etapa universitaria. Así mismo, a mis docentes universitarios por sus enseñanzas brindadas en esta gran etapa profesional. Finalmente, a la empresa Aluminios Laminados del Norte por las facilidades brindadas para el desarrollo de mi investigación.

ARTÍCULO-FINAL.pdf

INFORME DE ORIGINALIDAD

16%	15%	7%	7%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	tesis.usat.edu.pe Fuente de Internet	2%
2	hdl.handle.net Fuente de Internet	1%
3	tesis.pucp.edu.pe Fuente de Internet	1%
4	Submitted to Universidad Católica de Santa María Trabajo del estudiante	<1%
5	www.coursehero.com Fuente de Internet	<1%
6	repositorioacademico.upc.edu.pe Fuente de Internet	<1%
7	repository.libertadores.edu.co Fuente de Internet	<1%
8	Submitted to Universidad Católica Santo Toribio de Mogrovejo Trabajo del estudiante	<1%

Índice

Resumen	6
Abstract.....	7
Introducción.....	8
Revisión de literatura.....	10
Materiales y métodos.....	14
Resultados y discusión.....	16
Conclusiones.....	32
Recomendaciones	33
Referencias	35
Anexos.....	38

Resumen

El presente estudio abordó la problemática de la distribución de discos de aluminio sin una inspección de calidad adecuada, ya que el proceso se realizaba manualmente, lo que generaba pérdidas económicas y posibles riesgos para la salud de los consumidores de utensilios fabricados con este material. Como solución, se desarrolló un sistema inteligente basado en reconocimiento de imágenes para clasificar los discos según patrones visuales establecidos en la industria fundidora. Para lograrlo, se recopiló información sobre los defectos consultando a expertos en su fabricación. Seguidamente, se creó el algoritmo adecuado para procesar las imágenes de los discos, lo cual fue posible gracias a la metodología XP y Machine Learning. Como algoritmo adecuado para clasificar los discos con los estándares previamente definidos, se eligió a las redes neuronales convolucionales, las cuales fueron programadas con Python, mientras que la interfaz del sistema fue diseñada usando PHP con Laravel. Como entradas se utilizaron 1200 imágenes de 350 píxeles a color RGB, las cuáles se dividieron en dos grupos de imágenes buenas y otras con defectos relacionados a los defectos en el disco. El modelo desarrollado alcanzó una precisión del 97% en la detección de discos de aluminio aptos para su pase a venta, además de identificar la cantidad de discos dañados. Finalmente, se validó la experiencia de uso del sistema inteligente mediante el modelo TAM obteniendo un 98 % en facilidad de uso y utilidad percibida.

Palabras clave: discos de aluminio, reconocimiento de imágenes, utensilios de aluminio, modelo TAM.

Abstract

This study addressed the problem of the distribution of aluminum disks without an adequate quality inspection, since the process was carried out manually, which generated economic losses and possible health risks for consumers of utensils made of this material. As a solution, an intelligent system based on image recognition was developed to classify the discs according to visual patterns established in the foundry industry. To achieve this, information on the defects was gathered by consulting experts in their manufacture. Then, the appropriate algorithm was created to process the disc images, which was possible thanks to the XP methodology and Machine Learning. Convolutional neural networks were chosen as the appropriate algorithm to classify the disks with the previously defined standards, which were programmed with Python, while the system interface was designed using PHP with Laravel. As inputs, 1200 images of 350 pixel in RGB color were used, which were divided into two groups of good and flawed images related to disk defects. The developed model achieved an accuracy of 97% in the detection of aluminum discs suitable for sale, in addition to identifying the number of damaged discs. Finally, the experience of use of the intelligent system was validated by means of the TAM model, obtaining 98% in ease of use and perceived usefulness.

Keywords: aluminum disks, image recognition, aluminum utensils, model TAM.

Introducción

Inspeccionar la calidad de los productos metálicos como por ejemplo utensilios de cocina hechos de aluminio, es sin lugar a duda uno de los grandes desafíos que enfrentan las empresas dedicadas a su elaboración. En la actualidad, la inspección de calidad todavía se basa en gran medida en las habilidades humanas [1]. Sin embargo, con los avances en ciencia y tecnología informática, los métodos de inspección están evolucionando hacia el uso de sistemas usando inteligencia artificial en lugar de depender únicamente de la percepción humana [2], evitando así que productos defectuosos lleguen al consumidor final.

En este contexto, la calidad del producto terminado es de vital interés para el sector manufacturero debido al impacto en la salud de sus consumidores y por el gran aporte económico que hacen al país. Las empresas enfocadas en dicho rubro han permanecido en proyección de crecimiento en los últimos años, tal como se refleja en el reporte de actividades económicas del Banco Central de Reserva del Perú a enero del 2024 [3]. Dentro de este sector están aquellas dedicadas a la elaboración de discos de aluminio, el cual funciona como materia prima para la fabricación de utensilios de cocina como ollas, sartenes, teteras, entre otros, esto debido a su excelente conductividad de calor. En comparación con el cobre, el aluminio está por encima en un 50 a 60% [4]. Pese al crecimiento evidenciado en el dato anterior, la empresa aún enfrenta desafíos dentro de la gestión de sus procesos operativos. La selección de la materia prima y la inspección de calidad de los productos no son realizados bajo las medidas adecuadas, comprometiendo la calidad del disco de aluminio, y por ende, la salud de los consumidores [5] en especial de aquellos que sufren de enfermedades renales [6], generando pérdidas económicas para la empresa así como también daños a su reputación [7].

Por ello, se tuvo la necesidad de apoyar en la mejora de los procesos productivos de la empresa utilizando la solución tecnológica propuesta, garantizando su permanencia y distinción dentro del mercado competitivo [8]. En el Perú de acuerdo a la encuesta Nacional de Calidad a Micro y Pequeñas empresas del Sector Manufacturero 2017 [7], se reportó que aproximadamente el 22% de estas empresas tuvieron quejas por parte de sus clientes con respecto al tema de la calidad en sus productos.

La empresa Aluminios Laminados del Norte, dedicada a la elaboración de discos de aluminio para ollas, cuenta con una base de clientes distribuidos en diferentes puntos del norte peruano. Esta manifestó inconvenientes con respecto al proceso final de su cadena de producción, específicamente en la verificación de la calidad de los discos de aluminios terminados, el cual

se llevaba a cabo manualmente con ayuda del personal y de manera aleatoria al total del pedido a entregar, ocasionando el envío de piezas defectuosas a producción, dando lugar a reclamos por parte de los clientes, 4 de cada 10 llegaban a reclamar por discos que habían llegado con fallas y otros simplemente empiezan a buscar nuevos proveedores (ver anexo 01).

Aunque el aluminio está presente de manera natural en muchos alimentos, su transferencia a través de utensilios de cocina como ollas, sartenes o teteras puede ocurrir cuando estos entran en contacto con alimentos, especialmente los ácidos. Por esta razón, no se recomienda el uso de utensilios de aluminio con este tipo de alimentos. El Ministerio de Salud de Italia, reconociendo este riesgo, promulgó el “Reglamento sobre la regulación higiénica de los materiales y objetos de aluminio y aleaciones de aluminio destinados a entrar en contacto con los alimentos”, que obliga a las empresas especializadas en aluminio a etiquetar sus productos, advirtiendo que no son aptos para alimentos con alto contenido ácido [9]. Si bien el uso de aluminio en la industria alimentaria no representa un peligro para la salud, siempre que se respeten los estándares de calidad, su uso inapropiado puede generar riesgos, especialmente para segmentos vulnerables de la población, como niños menores de 3 años, adultos mayores, mujeres gestantes y personas con insuficiencia renal [5].

Por tal motivo, se destacó la importancia de incorporar soluciones tecnológicas en el proceso de inspección de calidad de los discos de aluminio terminados para tratar los problemas mencionados anteriormente como errores humanos, tiempos prolongados de inspección y la falta de uniformidad en los criterios de evaluación. La inteligencia artificial, en particular el reconocimiento de imágenes ha demostrado ser eficaz en sectores industriales. Un ejemplo de ello es el trabajo realizado por Soto [10], utilizó redes neuronales convolucionales para detectar defectos en envases de aluminio, y Ramos [9] aplicó visión artificial para clasificar mangos exportables. En la empresa materia de estudio, implementar esta tecnología permitió detectar defectos en los discos de aluminio de manera precisa, mejorando la calidad, reduciendo costos y tiempos de inspección, y aumentando la eficiencia del proceso al garantizar inspecciones continuas y uniformes, asegurando que solo los productos que cumplen con los criterios establecidos lleguen al cliente.

Dado lo expuesto anteriormente, surgió la siguiente interrogante: ¿De qué manera se puede mejorar el proceso de clasificación de discos de aluminio en una empresa fundidora en Chiclayo?

Con el objetivo principal de abordar estos desafíos, este estudio se enfocó en la implementación

de un sistema inteligente para clasificar discos de aluminio conforme a los estándares de calidad propuesto por la industria fundidora con la finalidad de evitar daños en la salud. Para ello, se procedió a caracterizar los patrones visuales de defectos en discos de aluminio de acuerdo a los estándares de calidad de la industria fundidora. Seguidamente se creó un algoritmo de inteligencia artificial capaz de reconocer, a través del procesamiento de imágenes, los patrones propuestos para los discos de aluminio en buen estado. Finalmente se validó la experiencia de uso del sistema inteligente mediante el constructo TAM.

Esta investigación desarrolló un sistema inteligente basado en Machine Learning y redes neuronales para clasificar discos de aluminio, logrando un impacto positivo en los ámbitos científico, tecnológico, económico y social. En el aspecto científico, aportó conocimientos sobre el uso de tecnologías avanzadas para evaluar la calidad de materiales metálicos mediante redes neuronales convolucionales. Tecnológicamente, la implementación del sistema mejoró la clasificación de piezas defectuosas, optimizando procesos en el sector metalmeccánico y avanzando hacia la Industria 4.0.

Desde el punto de vista económico, la adopción de esta tecnología permitió reducir los reclamos por productos defectuosos, optimizando recursos y tiempos de producción, lo que incrementó la rentabilidad y competitividad empresarial. Socialmente, la mejora en la detección de defectos minimizó riesgos para la salud al evitar que discos defectuosos lleguen al mercado, fortaleciendo así la calidad y seguridad de los productos finales.

Revisión de literatura

La aplicación de técnicas de Inteligencia Artificial y Machine Learning en el control de calidad ha demostrado su eficacia en diversos sectores industriales. Por ejemplo, Guallazaca [11], abordó la problemática en las empresas de producción agrícola en Ecuador, donde la clasificación de productos se realiza de forma manual y empírica, limitando el cumplimiento de los estrictos estándares de calidad necesarios para la exportación. Para superar esta limitación, se desarrolló un prototipo de clasificación mediante el uso de redes neuronales convolucionales (CNN) junto con el algoritmo K-Nearest Neighbor (KNN). El modelo fue entrenado con 50 imágenes por categoría, utilizando parámetros como la forma y el color de los productos. Los resultados demostraron una identificación precisa en bananas y manzanas sin errores, y tasas de error menores al 7% en naranjas y plátanos verdes, validando la eficacia del KNN en aplicaciones de control de calidad.

Por otro lado, Soto [10], abordó la inspección de barniz en latas de aluminio empleadas como envases para bebidas, donde la falta de barniz puede alterar el sabor y provocar insatisfacción en los consumidores. Para enfrentar este desafío, desarrolló un modelo de reconocimiento de imágenes basado en redes neuronales convolucionales, el cual se entrenó con un conjunto de 1776 imágenes de latas de aluminio, con y sin barniz, obtenidas bajo condiciones controladas y adecuadamente etiquetadas. El modelo logró una precisión global del 88% en la identificación de latas con y sin barniz, con una tasa de falsos positivos del 10%, nivel considerado aceptable. Este enfoque permitió reducir significativamente la posibilidad de que latas defectuosas llegaran a los consumidores, garantizando así la calidad del producto final.

León [12], destacó la problemática de la Empresa Cartavio Rum Company donde el control manual de embotellado y etiquetado resultaba en la comercialización de botellas con contenido irregular. Para resolver este problema, desarrolló un sistema de visión artificial capaz de detectar fallas o anomalías en la línea de producción de embotellado y etiquetado, logrando un índice de detección de productos defectuosos del 95%, en comparación con el 55% obtenido mediante inspección visual humana. Estos resultados evidenciaron cómo el sistema de visión artificial contribuye a un control de calidad más estricto en productos embotellados, reduciendo las insatisfacciones del cliente y mejorando la consistencia del producto final.

Así mismo, Córdova [13], analizó los altos costos y la carga laboral asociados con la inspección manual en baldosas de cerámica, que generaba además un desgaste significativo en el personal encargado de verificar la calidad. Para enfrentar este desafío, implementó un sistema de control de calidad automatizado mediante procesamiento digital de imágenes, diseñado para detectar defectos como grietas, fisuras y manchas en las baldosas de cerámica. Utilizando Matlab y una cámara industrial, el sistema integra herramientas de procesamiento de imágenes, tales como filtros, conversión a escala de grises, binarización y uso de histogramas para evaluar la calidad de las piezas. El sistema mostró resultados óptimos al automatizar el proceso de control de calidad, logrando reducir costos y mejorar la precisión de la inspección en comparación con los métodos manuales.

Ramos [14], abordó la problemática en una empresa agroindustrial dedicada a la exportación de mangos, que realizaba inspecciones manuales, lo cual ralentizaba el proceso y lo hacía vulnerable a errores humanos. Para resolver esta situación, Ramos desarrolló un sistema basado en Machine Learning para identificar mangos Kent exportables. Tras una recolección exhaustiva y preparación de datos, se utilizaron 1149 imágenes para entrenar y validar el

modelo. Los resultados fueron alentadores, alcanzando una efectividad del 85% en la detección de mangos aptos para exportación, lo que demuestra el potencial del aprendizaje automático para mejorar la eficiencia y precisión en la clasificación de productos agrícolas.

Por otro lado, La Madrid [15], presentó la problemática que enfrentan las empresas agrícolas en la verificación de la calidad de sus productos exportables, destacando la dependencia de procesos manuales que suelen ocasionar retrasos y errores. Para abordar esta situación, propuso un algoritmo de visión artificial implementado en Matlab, enfocado en identificar defectos en frutas como golpes, picaduras y exposición de la pulpa. El algoritmo empleó análisis de histogramas para evaluar la calidad de los melocotones en función de las características de los píxeles. El sistema obtuvo una precisión promedio superior al 80%, subrayando la importancia de condiciones óptimas de iluminación para el rendimiento del sistema. No obstante, el tiempo de procesamiento de 69.5 segundos podría considerarse elevado para aplicaciones industriales de gran escala.

Bases teóricas

La Inteligencia Artificial (IA), según Rouhiainen [16], es la capacidad de las computadoras para realizar tareas que típicamente requieren inteligencia humana. A través de algoritmos avanzados y grandes volúmenes de datos, la IA permite a las máquinas aprender y tomar decisiones autónomas. A diferencia de los humanos, estas máquinas pueden analizar grandes cantidades de información sin descanso y con un margen de error significativamente menor.

Entre las aplicaciones más destacadas de la IA se encuentra el Machine Learning o aprendizaje automático, que es una rama de la IA enfocada en el desarrollo de algoritmos que aprenden de manera autónoma sin requerir programación explícita [17]. A medida que estos algoritmos reciben más datos, su rendimiento mejora, lo que les permite adquirir y refinar su "inteligencia" para resolver problemas específicos. En el contexto del Machine Learning, existen tres enfoques de aprendizaje ampliamente utilizados [18]:

- Aprendizaje supervisado, donde el algoritmo se entrena con datos de entrada y sus salidas esperadas, identificando patrones que le permitan generar respuestas precisas.
- Aprendizaje no supervisado, en el cual el algoritmo examina datos sin etiquetas, buscando patrones o agrupaciones de manera autónoma.
- Aprendizaje por refuerzo, un enfoque en el que el algoritmo aprende mediante la

retroalimentación de premios y castigos, ajustando sus acciones para maximizar recompensas a lo largo del tiempo.

Una de las arquitecturas más influyentes en el Machine Learning es la de las Redes Neuronales Artificiales (RNA). Inspiradas en el funcionamiento de las neuronas biológicas del cerebro humano, las RNA son modelos matemáticos que buscan emular cómo el cerebro procesa la información [19]. Actualmente, las RNA se utilizan en una amplia gama de aplicaciones, desde diagnósticos médicos mediante la clasificación de imágenes hasta el análisis de comportamientos y la predicción de eventos. Su capacidad para reconocer patrones y realizar predicciones con gran precisión las ha convertido en una herramienta valiosa en sectores como el control de calidad y la identificación de compuestos químicos [20].

Entre los distintos tipos de redes neuronales, las Redes Neuronales Convolucionales (CNN) ocupan un lugar destacado debido a su eficacia en tareas de procesamiento de imágenes. Las CNN aplican operaciones matemáticas específicas llamadas convoluciones, las cuales permiten extraer características relevantes de las imágenes para su posterior reconocimiento y clasificación [20]. Gracias a su capacidad para identificar patrones visuales complejos, las CNN han sido fundamentales en el avance de tecnologías de visión por computadora.

Además de las aplicaciones de IA en sectores como la salud y la visión por computadora, el uso de algoritmos avanzados ha comenzado a extenderse al sector industrial, como en el caso de empresas manufactureras que usan el aluminio. Este elemento metálico, uno de los metales no ferrosos más utilizados debido a su abundancia, es altamente valorado por su baja densidad, ligereza y excelente conductividad térmica y eléctrica [21]. Las propiedades del aluminio, junto con su alta reciclabilidad, lo convierten en un material esencial en la industria moderna.

Un ejemplo destacado de la versatilidad del aluminio son los discos de aluminio, piezas elaboradas en diversas aleaciones y en espesores delgados, con distintos diámetros, dependiendo del uso final. Debido a su ligereza, ductilidad y capacidad para esparcir el calor de manera uniforme, estos discos son ampliamente empleados en la fabricación de utensilios de cocina, como ollas, sartenes y cacerolas [22].

Nuestra investigación aborda específicamente la problemática de la clasificación de calidad de estos discos de aluminio. Antes de su transformación en productos finales, es fundamental detectar defectos en la textura de los discos, ya que estos pueden afectar la calidad de los utensilios de cocina que se fabriquen con ellos. La aplicación de técnicas de IA y Machine

Learning en este contexto permite realizar una clasificación de calidad automatizada, asegurando que solo las piezas sin defectos pasen al siguiente proceso de producción, mejorando así la eficiencia y reduciendo el margen de error.




Fig. 1. Discos de aluminio. Fuente [22]

Materiales y métodos

Tipo de investigación

De acuerdo a lo leído en el Manual de Frascati [23], la investigación realizada se definió como aplicada dado que esta se centró en utilizar los conocimientos adquiridos en inteligencia artificial y machine learning para desarrollar un producto tecnológico que dé solución a la problemática planteada.

Métodos de investigación

Se empleó los siguientes métodos de investigación:

TABLA I. MÉTODOS DE INVESTIGACIÓN

Método	Descripción
Analítico	Análisis del proceso de inspección del control de calidad de los discos de aluminio de la empresa Aluminios Laminados del Norte para identificar la problemática.
Experimento	Entrenamiento del modelo de machine learning con data fotográfica de discos de aluminio.
Implementación	Ejecución del sistema inteligente propuesto como solución para identificar los defectos del disco de aluminio.

Técnicas e instrumentos

A continuación, se presentan las técnicas e instrumentos usados para la recolección de datos:

TABLA II. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Técnicas	Instrumentos	Elementos de la población	Propósito
Entrevista	Guía de preguntas abiertas (ver Anexo 1)	Administrador de la empresa	Conocer la problemática
Observación	Grabación de imágenes	Operarios de la empresa	Conocer los procesos que se realizan.

Metodología de desarrollo

El desarrollo del sistema inteligente propuesto se llevó a cabo siguiendo la metodología general de Machine Learning, la cual consta de las siguientes etapas: definir el objetivo, recopilación de los datos, preparar los datos, elección del algoritmo, entrenar el modelo, validación del modelo y la predicción. Las actividades realizadas en cada etapa se detallan a continuación:

I. Fase 1. Definir el Objetivo:

- Identificar el problema a estudiar.
- Determinación de requerimientos funcionales y no funcionales.

II. Fase 2. Recopilación de los datos:

- Recolección de imágenes fotográficas de discos de aluminio usados para entrenar y validar nuestro modelo.

III. Fase 3. Preparar los datos:

- Procesamiento de las imágenes de los discos de aluminio para la limpieza, conversión de tamaños y categorización de la data a usar en el modelo.

IV. Fase 4. Elección del algoritmo:

- Elección del algoritmo idóneo para nuestro problema entre algoritmos de aprendizaje supervisado y aprendizaje no supervisado.

V. Fase 5. Entrenar el modelo:

- División de la data destinada al entrenamiento del algoritmo elegido.

VI. Fase 6. Validación del modelo:

- Se usó la data destinada a la validación de nuestro algoritmo elegido.

VII. Fase 7. Predicción:

- Implementación del sistema web con el modelo desarrollado para detectar los discos de aluminio defectuosos.

Resultados y discusión

En base a la metodología utilizada

Fase 1. Definir el objetivo

Se identificó el problema a resolver mediante un modelo de machine learning, que tiene la capacidad de clasificar entre discos de aluminio defectuosos o no, es decir que estén aptos o no para su venta. Según los especialistas de la empresa, los defectos identificados incluyen "globos" o "carachas" (términos usados en la empresa). Vender discos con estos defectos genera insatisfacción entre los clientes, aproximadamente 4 de cada 10, presentando reclamos por estas imperfecciones (Ver anexo 01).

Nos enfocamos en la verificación de los defectos en la textura de los discos para determinar si son aptos para la venta. Realizar este proceso manualmente demandaba un gran esfuerzo visual. El sistema que se implementó fue capaz de apoyar a personas no expertas en la identificación de estos defectos, proporcionando un diagnóstico con un alto grado de precisión (mayor al 80%) sobre la calidad de los discos de aluminio y en un tiempo considerablemente rápido. De esta manera no solo se brindó una solución a los problemas de la empresa, sino que además al filtrar estos discos defectuosos garantizamos que estos discos no lleguen a los consumidores finales y por ende poner en riesgo su salud.

Fase 2. Recopilación de los datos

En esta etapa se definió la ruta a seguir para la obtención de la data en este caso las imágenes de discos de aluminios. Debido a su escasa o nula existencia en internet sobre estos y de acuerdo con las características que necesitaban tener las mismas para ser entrenadas, se tuvo la necesidad de trabajar con una recolección de imágenes local, es decir en la propia empresa materia de estudio y principal fuente de obtención de las imágenes, también fue complementada esta obtención con una fábrica local que contaba con dichos discos de aluminios.

Para la adquisición de los discos que presentaban o no defectos, se recibió una orientación por parte del dueño de la empresa, adicionalmente de la experiencia de un fabricante de ollas local, esta orientación sirvió como base para proponer los patrones visuales de defectos en los discos. Sobre los discos que presentaban fallas se mostraron defectos como "globos" y "carachas" los

cuales fueron clasificados como “no aptos”, además los discos que no presentaban las fallas antes mencionadas fueron clasificados como “aptos”. Posterior a ello se procedió a buscar las herramientas y ambiente para llevar a cabo la toma de fotografías de los discos, los cuales se detallarán en el siguiente punto.

Se lograron obtener un total de 1200 imágenes entre discos fallados y sin fallas. Las condiciones en cuanto al ambiente y características mínimas bajo las que fueron tomadas las imágenes se detallan a continuación:

Cámara celular:

- Resolución 12 megapíxeles
- Modo profesional, el cual nos permitió ajustar parámetros como ISO (es la sensibilidad que tiene los sensores de las cámaras para la entrada de luz al lente, el valor de ISO usado fue de 100) y tiempo de exposición (es la velocidad y tiempo en la que permanece abierto el obturador de la cámara para permitir el acceso de luz, el valor usado fue de 1/40 segundos).
- Relación de aspecto: 1:1 (cuadrado)
- Estabilización: se usó un trípode que permitiera mantener estabilizado el celular y poder ajustar el ángulo de visión.

Ambiente:

- Iluminación: se empleó el uso de 2 reflectores de luz blanca ubicados estratégicamente para obtener buenos resultados y tener una imagen detallada de los discos de aluminios.
- Entorno: se usó una base con fondo negro para lograr resaltar de mejor manera el disco de aluminio.

Fase 3. Preparar los datos

Para lograr mejores resultados en el entrenamiento del modelo se verificó que las imágenes tomadas tengan buena calidad y cumplan con ciertas condiciones como no contar con objetos ajenos al disco de aluminio, que no exista bordes iluminados intensamente en el disco producto de una mala toma fotográfica y se verificó que estén tomadas en un formato 1:1 (cuadrada).

Luego de realizar la verificación de calidad de las imágenes con los criterios anteriormente mencionados se obtuvo un total de 1000 imágenes repartidas en 500 sin fallas y 500 con fallas, las cuales fueron usadas para el entrenamiento del modelo.

Finalmente, las imágenes fueron repartidas en 3 grupos: Entrenamiento (80%), Prueba (15%) y Validación (5%), como se observa a continuación:

- ENTRENAMIENTO: (80%) (800 imágenes)
 - BUENAS: 400 imágenes
 - MALAS: 400 imágenes
- PRUEBA: (15%) (150 imágenes)
 - BUENAS: 75 imágenes
 - MALAS: 75 imágenes
- VALIDACIÓN: (5%) (50 imágenes)
 - BUENAS: 25 imágenes
 - MALAS: 25 imágenes

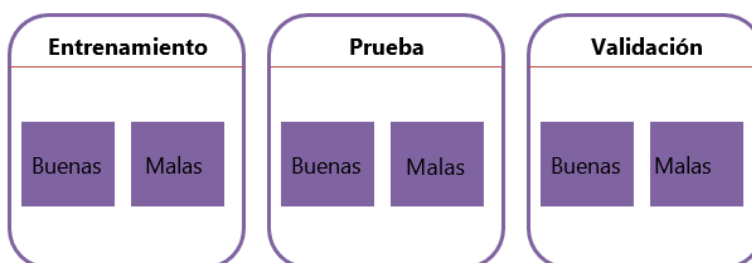


Fig. 2. Clasificación de las imágenes.

Fuente: Elaboración propia

Después de clasificar y limpiar los datos de las imágenes, se procedió a su procesamiento para el modelo implementado. Se implementó una función en Python usando Google Colab y OpenCV, que recorre las carpetas de imágenes utilizando las librerías de OpenCV para visión artificial y aprendizaje automático.

```

train_dir = "/content/drive/My Drive/imagenes/Entrenamiento/"
test_dir = "/content/drive/My Drive/imagenes/Prueba/"

LOAD_FROM_IMAGES = False

def get_data(folder):
    X = []
    y = []
    for folderName in os.listdir(folder):
        if not folderName.startswith('.'):
            if folderName in ['MALAS']:
                label = 0
            elif folderName in ['BUENAS']:
                label = 1
            else:
                label = 2
            for image_filename in tqdm(os.listdir(folder + folderName)):
                img_file = cv2.imread(folder + folderName + '/' + image_filename)
                if img_file is not None:
                    img_file = img_file / 255.0
                    img_file = skimage.transform.resize(img_file, (350, 350, 3), mode='constant', anti_aliasing=True)
                    img_arr = np.asarray(img_file)

                    X.append(img_arr)
                    y.append(label)
    X = np.asarray(X)
    y = np.asarray(y)

    return X,y

```

Fig. 3. Código para el procesamiento de las imágenes.

Fuente: Elaboración propia

Como se observa en la *Fig. 3*, se redimensionaron las imágenes a un tamaño estándar de 350 x 350 píxeles. Esto se hizo porque, al recortar las imágenes, algunas tenían tamaños diferentes. Se buscó no perder calidad ni detalle, por lo que se eligió un tamaño de 350 píxeles de alto y ancho, lo que permite obtener resultados óptimos en el procesamiento. Las imágenes se procesaron en escala de 3 colores RGB.

Después del preprocesamiento, todas las imágenes se almacenaron en una carpeta específica en Google Drive en forma de arreglos, al finalizar la ejecución de la función. Este enfoque evitó la recarga de imágenes al ajustar el modelo en el futuro. Si se necesita reentrenar el modelo, solo será necesario llamar al arreglo previamente guardado, optimizando significativamente el tiempo para posibles modificaciones.

Se asignaron valores de 0 a las imágenes clasificadas como "Malas" y de 1 a las "Buenas".

Fase 4. Elección del algoritmo

Para la elección del mejor algoritmo de Machine Learning para nuestra problemática seguimos la siguiente secuencia:

Criterios de evaluación:

Los criterios para evaluar la comparación de algoritmos fueron organizados en cinco aspectos claves. Tres de estos criterios derivan de los factores de calidad de software planteados por MCCall [24], mientras que los dos faltantes están vinculados a

características específicas de aprendizaje del software planteado. Es esencial examinar el tipo de aprendizaje del algoritmo y su capacidad para aceptar una imagen como entrada, garantizando así que el algoritmo seleccionado esté alineado con la naturaleza del problema a abordar.

Los criterios que fueron considerados son los siguientes:

Tiempo: Este criterio evalúa el tiempo promedio requerido para implementar el algoritmo.

Reusabilidad: Se refiere al grado en que un algoritmo o sus componentes pueden ser utilizados en diversas aplicaciones, destacando la capacidad de reutilización.

Interoperación: Evalúa el esfuerzo necesario para integrar el algoritmo con uno o varios sistemas existentes.

Aprendizaje: Se analiza si el algoritmo de machine learning sigue un enfoque de aprendizaje supervisado. Dado que el proyecto implica imágenes ya categorizadas como "Buenas" y "Malas", fue fundamental que el algoritmo posea esta característica en su método de aprendizaje.

Input image: Este criterio asegura que el algoritmo permita como datos de entrada, en su capa inicial, píxeles de una imagen.

Escala de Valores:

TABLA III. Escala de Valoración

Calificativo		Puntaje
C1, C2, C3	C4, C5	
Bajo	Cumple	3
Medio		2
Alto	No cumple	1

Elección del algoritmo

En la elección del algoritmo más adecuado para nuestro proyecto, se realizó una comparación entre los principales algoritmos de machine learning. Aplicamos los criterios mencionados previamente a cada uno de estos algoritmos, asignándoles un coeficiente de peso que varía desde P1 hasta P5. La asignación de estos pesos se realizó de acuerdo al nivel de prioridad que los criterios ostentaban en nuestro trabajo con respecto al resto.

TABLA IV. Criterios para la elección del algoritmo

Criterio	Coficiente	Valor
C5: Input image	P5	0.3
C4: Aprendizaje	P4	0.3
C1: Tiempo	P1	0.2
C3: Interoperación	P3	0.1
C2: Reusabilidad	P2	0.1

Teniendo en cuenta los criterios y valores anteriores de la tabla se procedió a comparar 5 algoritmos de machine learning asignando su peso y valor correspondiente.

TABLA V. Comparación de algoritmos

Algoritmos	Criterios					Total
	C1	C2	C3	C4	C5	
	P1 = 0.2	P2=0.1	P3=0.1	P4=0.3	P5=0.3	Ci*Pi
Clustering K-Means	2	1	3	1	1	1.4
Regresión Lineal	1	2	3	3	1	1.9
Bayesian Network	2	1	3	1	3	1.8
Convolutional Neural Networks	2	3	3	3	3	2.8
Long Short Term	1	2	3	3	3	2.5

Luego de la asignación de puntajes podemos notar que el que más se adaptó a nuestras necesidades es Convolutional Neural Networks (Red Neuronal Convolutiva) el cual obtuvo un puntaje de 2.8, por ende, se procedió a usarlo en nuestro trabajo de investigación.

Fase 5. Entrenar el modelo

Luego de haber categorizado nuestra data de imágenes con la limpieza y verificación correcta, además de la elección del algoritmo idóneo se procedió a entrenar nuestro modelo. Optamos por utilizar la librería Keras, la cual se distingue por simplificar la creación de soluciones para desafíos asociados al aprendizaje profundo y el tratamiento de modelos de redes neuronales convolucionales. Es relevante señalar que dicha librería está desarrollada en el lenguaje de Python, que sirvió como fundamento para la construcción de nuestro modelo. Además, se

incorporó la librería Tensorflow, la cual ocupa un lugar destacado en el campo del aprendizaje profundo.

Se configuró la forma que espera nuestro modelo, adaptándola al tamaño de 350 x 350, teniendo en cuenta la redimensión realizada durante el preprocesamiento de las imágenes y en dimensión RGB, es decir, en 3 colores. Después del procesamiento de la imagen de entrada, se realizó una nueva exploración sobre el mapa de características generado por la capa anterior, utilizando la técnica de Max Pooling a través del método MaxPooling2D. Se definió una tupla con dimensiones de 2 x 2 para extraer las características principales y obtener así nuestro primer paso de convolución pooling.

Con el objetivo de distinguir las características de las imágenes y evaluar la calidad del disco, se consideró la posibilidad de incorporar dos pasos de convolución pooling de manera análoga al mencionado anteriormente. No obstante, en este escenario, no se detalla el tamaño de entrada, debido a que dichas capas se nutrirán de los resultados obtenidos en el primer paso de convolución pooling. Por último, se declaró una capa de salida con dos neuronas, indicando las posibilidades que el disco presente o no defectos. Para lograr esto, se ha aplicado la función de activación softmax en esta capa.

Una vez establecida la configuración de nuestro modelo, la etapa subsiguiente implicó su compilación. En este procedimiento, se optó por emplear el optimizador de aprendizaje Adam, mientras que la función de pérdida seleccionada fue la `sparse_categorical_crossentropy`. La elección de esta función se fundamenta en el hecho de que las etiquetas correspondientes a las imágenes están representadas en una matriz plana de ceros y unos, donde el valor cero indica la etiqueta "Malas" y el valor uno, la etiqueta "Buenas". Respecto a las métricas utilizadas, se tuvo en cuenta la precisión.

Como último paso para esta fase fue el entrenamiento del modelo. Proporcionamos como parámetro el conjunto de datos de entrenamiento, que se transformó en etapas previas, junto con el conjunto de etiquetas. Se ha incorporado un `batch_size` de 32 (aunque inicialmente se probó con 80 y no proporcionó resultados favorables), lo que implica que la red aprenderá de las imágenes en grupos de 32 hasta que se completen todas las muestras. Adicionalmente, se especificaron las épocas deseadas para entrenar el modelo. Inicialmente, fijamos esta variable en 10, pero al observar un aumento continuo en la precisión, se decidió incrementarla a 20 épocas. La elección de esta variable impacta en la duración del proceso de entrenamiento del modelo.

A continuación, en la tabla podemos observar el resultado de las épocas:

TABLA VI. Datos de entrenamiento

Época	Precisión
1	0.6037
2	0.8188
3	0.8838
4	0.92.50
5	0.9262
6	0.9375
7	0.9325
8	0.9488
9	0.9550
10	0.9588
11	0.9550
12	0.9600
13	0.9625
14	0.9625
15	0.9638
16	0.9712
17	0.9550
18	0.9613
19	0.9600
20	0.9575

Analizando el escenario de entrenamiento llegamos a tener un lost (o pérdida) de 7% en la época 16 y una precisión máxima del 97% en la misma época. Y ya para la época final 20 logramos tener una precisión del 95% y una pérdida del 9%, con estos resultados ya podemos decir que nuestro modelo ya está en capacidades de aprendizaje para poder diferenciar las imágenes que sean ajenas al entrenamiento.

Fase 6. Validación del modelo

Luego de haber entrenado nuestro modelo, procedimos a realizar la validación con nuestros datos de prueba los cuales fueron un total de 150 imágenes, de las cuales 75 son de discos buenos y 75 de malos.

Los resultados que obtuvimos fueron de una pérdida casi nula con un 0.0045% y una precisión del 100%. Como podemos observar en la siguiente imagen.

```
test_loss, test_acc = model.evaluate(X_testReshaped, y_test)
print(test_acc)

5/5 [=====] - 40s 6s/step - loss: 0.0045 - accuracy: 1.0000
1.0
```

Fig. 4. Resultado con los datos de prueba.

Fuente: Elaboración propia

Luego de haber realizado las pruebas correspondientes a la validación de nuestro modelo procedimos a guardar nuestro modelo entrenado para así poder integrarlo a nuestro sistema. Se guardó tanto el modelo como sus pesos respectivos para futuras implementaciones.

Fase 7. Implementación

En esta etapa final, el objetivo fue asegurar que los resultados generados por el modelo entrenado sean fácilmente comprensibles y se integren, si es necesario, con otro sistema. Se logró una integración exitosa del modelo entrenado en Python con nuestro sistema web. La comunicación se llevó a cabo mediante HTTP empleando el método POST mediante la comunicación por API, usando un servidor Flask de manera local, lo que hacemos es enviar un archivo de tipo imagen desde la web hacia el API de nuestro modelo y nos devolverá un resultado con el porcentaje y la condición de si el disco es bueno o no.

```
async function predecir(formData) {
  event.preventDefault();
  var response;
  try {
    response = await $.ajax({
      type: "POST",
      url: "http://127.0.0.1:5000/diagnostico2",
      data: formData,
      processData: false,
      contentType: false,
    });
    return response;
  } catch (error) {
    toastr.error("Error de conexión con el servidor FLASK", "¡Error!");
    $("#loading").addClass("d-none");
  }
}
```

Fig. 5. Extracto de código para la conexión con nuestra API.

Fuente: Elaboración propia

A continuación, mostramos la integración de nuestra web con el API. Se selecciona el archivo que es donde subimos la imagen a analizar y luego se mostrará la predicción con su porcentaje y la descripción de si el disco es bueno o no.

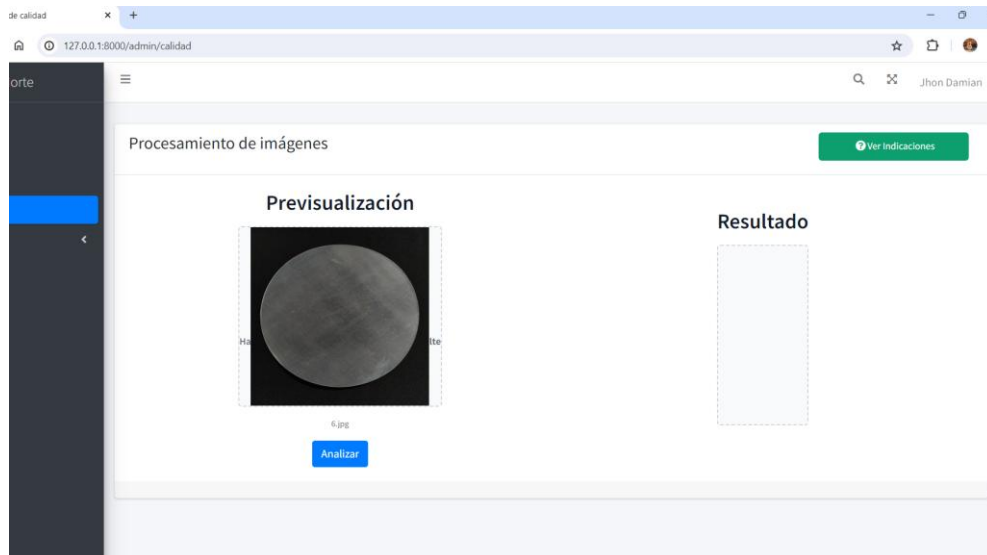


Fig. 6. Interfaz de análisis de imagen de disco de aluminio.

Fuente: Elaboración propia

En la imagen anterior se observa la interfaz al seleccionar el archivo a subir para su análisis. Y en la imagen mostrada a continuación se observa el resultado del análisis.

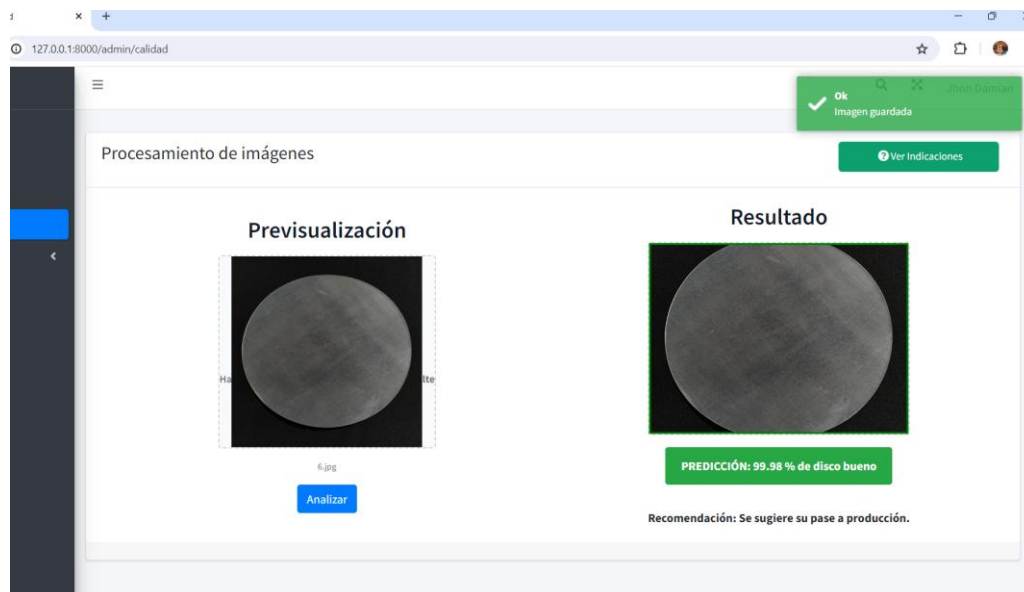


Fig. 7. Resultado de análisis de disco analizado.

Fuente: Elaboración propia

En base a los objetivos del proyecto

Objetivo 1: Proponer patrones visuales de defectos en discos de aluminio de acuerdo a los estándares de calidad de la industria fundidora.

Para alcanzar este objetivo, fue fundamental la recopilación de imágenes tanto de discos en buen estado como de discos defectuosos. Tal como se describió en la sección de metodología de *machine learning* de este documento, durante la fase de recopilación y preparación de datos, se obtuvieron inicialmente 1200 imágenes. Sin embargo, tras un proceso de filtrado en el que se descartaron aquellas que no cumplían con los criterios de calidad requeridos para el entrenamiento del modelo, se seleccionaron finalmente 1000 imágenes, las cuales fueron utilizadas en el desarrollo del modelo.

Al contar con esta selección final de imágenes, se procedió a analizar las características de los discos de aluminio para identificar los criterios utilizados por la empresa para determinar su calidad. Durante el análisis de las imágenes que la empresa consideró defectuosas, se observó que la mayoría presentaba “globitos”, que podían variar en tamaño y cantidad. Además, se identificaron piezas con “carachas”, un tipo de abertura que se forma en el disco. Estos defectos se detallan a continuación en las imágenes presentadas.

Las características de los patrones de calidad encontrados podemos enumerarlas de la siguiente manera:

1. Discos con presencia de defectos de tipo “globos”, los cuales se generan debido a un exceso de temperatura durante el proceso de fundición (ver Anexo 01). La aparición de este defecto indica que el disco no cumple con los estándares de calidad necesarios para continuar en la cadena de producción destinada a la venta al público. Este defecto se puede observar en la imagen 8 presentada a continuación.




Fig. 8. Disco defectuoso con presencia de "globitos".

Fuente: Elaboración propia

- Discos con presencia de defectos tipo “carachas”, los cuales se originan por una falta de limpieza durante el proceso de fundición del aluminio (ver Anexo 01). La aparición de este defecto indica que el disco no cumple con los estándares de calidad requeridos para continuar en la cadena de producción y ser destinado a la venta al público. Este defecto se puede observar en la Fig. 9 presentada a continuación.




Fig. 9. Disco con abertura o "carachoso".

Fuente: Elaboración propia

- Los discos que son considerados aptos para su venta, se caracterizaron por tener un aspecto limpio, aunque en algunos casos presentaban ligeras rayaduras en su superficie interior. Estas rayaduras solían aparecer debido al manejo inadecuado durante el transporte, al no tomarse las medidas necesarias para proteger el acabado del disco. En las imágenes siguientes se puede observar, a la izquierda (Fig. 10), un disco en buen estado con acabado limpio, pero con presencia de rayaduras, y a la derecha (Fig. 61), un disco mejor conservado y totalmente limpio.



Fig. 10. Disco de buena calidad con rayaduras

Fuente: Elaboración propia




Fig. 11. Disco de buena calidad.

Fuente: Elaboración propia

La identificación de estos patrones fue fundamental para el desarrollo del algoritmo, permitiendo alcanzar el objetivo de que nuestro sistema inteligente pueda distinguir entre discos aptos para su venta y aquellos con defectos. Esto se logró mediante la aplicación de la metodología de machine learning, que siguió una ruta lógica a través de sus distintas fases: recopilación de requisitos, recolección de imágenes, preparación y balanceo de los datos, y finalmente, el entrenamiento en el modelo de red neuronal implementado. Adicionalmente, en el desarrollo de nuestra metodología XP, las pruebas realizadas demostraron que el sistema es capaz de reconocer con precisión cuándo un disco presentaba defectos y cuando no.

Objetivo 2: Crear el algoritmo de inteligencia artificial que permita reconocer los patrones propuestos mediante procesamiento de imágenes de los discos de aluminio.

Este objetivo se logró, como se describió en los puntos desarrollados anteriormente tanto en la metodología de machine learning (para el desarrollo del algoritmo) como en la metodología XP, las cuales fueron fundamentales para crear e integrar nuestro algoritmo de red neuronal en el sistema inteligente. El sistema permite cargar una imagen del disco de aluminio y evaluar su calidad para determinar si el disco es apto para salir a la venta.

El primer paso fue seleccionar el algoritmo de aprendizaje automático que mejor se ajustara a las necesidades de la problemática planteada. Esta elección se explicó en la Fase 4 de nuestra metodología de machine learning. Tras un análisis exhaustivo de la información recopilada, se determinó que el algoritmo más adecuado era la Red Neuronal Convolutiva (Convolutional Neural Network, CNN). Luego de esta elección, se procedió con las siguientes fases de la metodología, incluyendo la Fase 5 de entrenamiento del modelo y la Fase 6 de validación del modelo. Finalmente, se implementó la comunicación entre el modelo entrenado y el sistema web, tal como se detalla en secciones anteriores de este documento.

Para implementar nuestro sistema web, se siguió la metodología XP, la cual permitió determinar los requerimientos necesarios para el funcionamiento del sistema y definir su arquitectura. Además, se realizaron las pruebas pertinentes para validar la usabilidad del sistema. Se desarrolló el módulo de control de calidad, que constituye el núcleo de nuestra solución. Este módulo permite cargar una imagen de un disco y, mediante la conexión con nuestro servidor Flask donde se encuentra alojado el modelo entrenado, proporciona el resultado de la predicción, indicando si el disco presenta defectos o no.

Asimismo, se identificó la necesidad de que el sistema pueda verificar si la imagen cargada

corresponde a un disco o no. En función de esta verificación, el sistema es capaz de generar la predicción correspondiente.

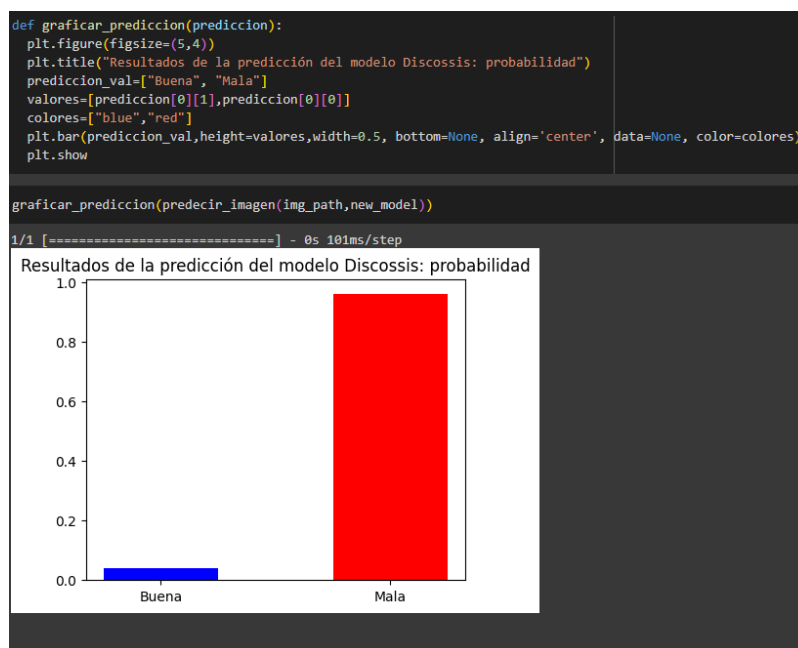


Fig. 12. Extracto de Código del modelo ya entrenado.

Fuente: Elaboración propia

En la imagen anterior, podemos observar el resultado de las pruebas realizadas al analizar una imagen de un disco. En esta función, se interpreta de manera gráfica el resultado generado por nuestro algoritmo entrenado. Este modelo tiene dos posibles salidas: "Buena" o "Mala". En el caso presentado, el modelo arrojó una predicción indicando que el disco es de mala calidad.



Fig. 13. Evidencia del resultado que arroja nuestro para validar la calidad o no del disco.

Fuente: Elaboración propia

En la Fig. 13, podemos observar el algoritmo implementado en comunicación con nuestro sistema web. Al subir una imagen de un disco mediante el módulo de control de calidad, el sistema genera la predicción correspondiente. En este caso, el resultado de la predicción indicó que el disco no presenta defectos y por tanto puede continuar su pase a producción o venta.

Objetivo 3: Validar la experiencia de uso del sistema inteligente mediante el constructo TAM

El cumplimiento de este objetivo se alcanzó mediante la aplicación del Modelo de Aceptación Tecnológica (TAM) propuesto por Davis [25], que evaluó la utilidad (hasta qué grado los usuarios perciben que el sistema mejora su desempeño) y la facilidad de uso (hasta qué punto los usuarios consideran que el sistema requiere menos esfuerzo). Las encuestas para este constructo fueron realizadas con un grupo de usuarios, compuesto por aproximadamente 10 personas, tanto internas de la empresa como externas, con el fin de obtener una visión amplia sobre la percepción del sistema. El cuestionario diseñado para estas pruebas se encuentra detallado en el Anexo N° 02.

Luego de aplicar el cuestionario al grupo de usuarios seleccionados, las respuestas recibidas por cada pregunta son las siguientes:

TABLA VII. Resultados de las respuestas del cuestionario TAM aplicado

Usuario	Facilidad de uso percibida					Utilidad percibida				
	P1	P2	P3	P4	P5	P1	P2	P3	P4	P5
MA (+)	9	8	10	8	9	9	9	10	8	9
A	1	2	0	1	1	1	1	0	1	1
N	0	0	0	1	0	0	0	0	1	0
D	0	0	0	0	0	0	0	0	0	0
MD (-)	0	0	0	0	0	0	0	0	0	0

Como resultado del análisis de la tabla anterior, el porcentaje de personas que perciben la facilidad de uso en el sistema fue del 98% mientras que el 2% considera que aún no es fácil de usar.

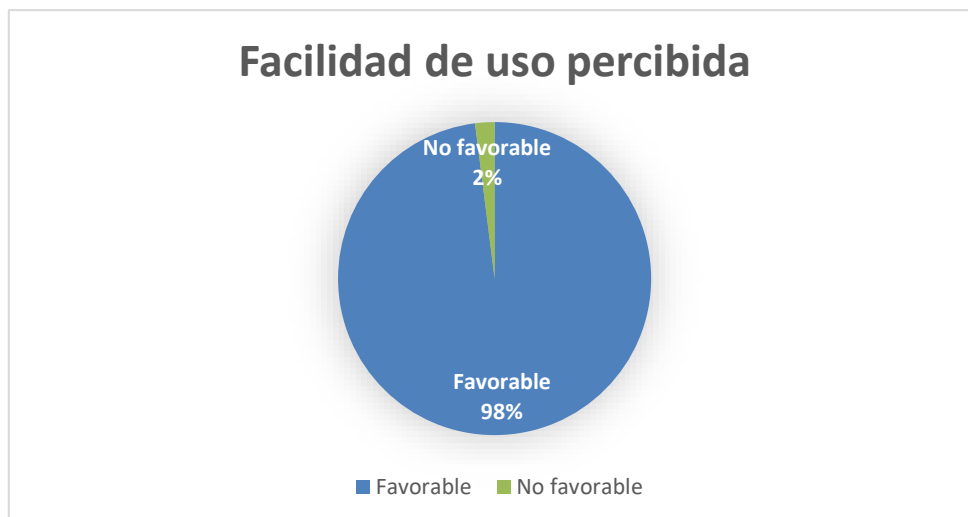


Fig. 14. Porcentaje de resultados favorables y no favorables de Facilidad de uso percibida.

Fuente: Elaboración propia

Por otro lado, el porcentaje de personas que encuentran útil el sistema desarrollado fue del 98% mientras que el 2% considera que aún falta ajustes por mejorar.



Fig. 15. Porcentaje de resultados favorables y no favorables de Utilidad percibida.

Fuente: Elaboración propia

Como complemento a estas encuestas, también se llevaron a cabo pruebas de caja negra y caja blanca durante la etapa de pruebas de nuestra metodología XP. Estas pruebas permitieron verificar el correcto funcionamiento del sistema desde una perspectiva técnica y arrojaron resultados favorables en cuanto a la ejecución de las funciones del sistema inteligente.

Consideramos que las pruebas realizadas, tanto a nivel de usuarios como a nivel técnico, proporcionaron una validación sólida de que se ha cumplido el objetivo de garantizar tanto la funcionalidad como la usabilidad del sistema.

Discusión

En el presente estudio elaborado con el fin de verificar la calidad en los discos de aluminio mediante el uso de redes neuronales, y luego de haber hecho una comparativa con diferentes algoritmos se demostró que el algoritmo que mejor se ajustaba a nuestro problema era las redes neuronales convolucionales el cual nos arrojó un puntaje de 2.8, siendo el más alto. Este tipo de algoritmo fue empleado por Ramos [14] quien lo usó para el análisis de los mangos de kent que podían ser exportables o no en base a su textura y color.

Además, Guallazaca [11], abordó la problemática de las empresas de producción agrícola ecuatoriana, donde la clasificación de productos se realiza de forma manual y empírica, lo que afecta la capacidad de satisfacer los estándares de calidad para su exportación. En su estudio, desarrollaron un prototipo de clasificación utilizando redes neuronales convolucionales logrando identificaciones precisas y tasas de error inferiores al 7% en varios tipos de frutas. Este enfoque destaca la eficacia de las redes neuronales en aplicaciones de control de calidad, similar a los logros de clasificación de discos de aluminios aptos o no para su venta, entrenados en base a patrones visuales obtenidos en nuestra investigación.

Soto [10] y León [12], abordaron el problema de la inspección de envases en la línea de producción mediante técnicas de machine learning, utilizando redes neuronales para el reconocimiento de imágenes. Los principales desafíos que enfrentaron incluían la insuficiencia del control de calidad visual para identificar envases defectuosos, dado que este proceso se realizaba de forma manual. Con la implementación del reconocimiento de imágenes, lograron mejorar la precisión de la detección de envases defectuosos, alcanzando un 85% y 90% de precisión, respectivamente. En comparación, nuestro estudio, basado en redes neuronales convolucionales, obtuvo una precisión del 97%, superando estos resultados y demostrando un avance significativo en la detección automática de defectos.

Conclusiones

La implementación del sistema inteligente desarrollado para la clasificación de discos de aluminio, basado en el análisis de patrones visuales, en una empresa laminadora de discos de aluminio en Chiclayo, demostró un alto porcentaje de precisión del 97% en la detección de estos productos. Este logro contribuye de manera significativa a mejorar el proceso de selección de las piezas antes de su envío para la venta, garantizando que los productos lleguen en óptimas condiciones a los consumidores finales.

Los patrones visuales de calidad en los discos de aluminio, basados en los defectos que puedan presentar en su textura, se han clasificado en dos categorías: “globos” y “carachas”, siendo estos considerados “no aptos”. Por otro lado, aquellos discos que no presenten los defectos mencionados se clasifican como “aptos”. Las láminas evaluadas mediante el algoritmo desarrollado eran identificadas en esta clasificación. Cuando estas láminas llegaban a manos del cliente y eran procesadas para su transformación en utensilios de cocina, como ollas, se generaban aberturas, lo que ocasionaba pérdidas económicas. Además, esto podría representar un riesgo para la salud de los consumidores finales al estar en contacto con los alimentos.

El modelo entrenado alcanzó una precisión superior al 97% en la identificación tanto de discos en buen estado como de aquellos con defectos, durante las fases de prueba y validación. Además, el algoritmo desarrollado ofrece un análisis con tiempos de respuesta rápidos, lo que es fundamental para su integración en líneas de producción industriales.

Finalmente, los resultados de la validación tecnológica mediante el modelo de aceptación tecnológica (TAM) mostraron un alto grado de utilidad percibida y facilidad de uso por parte de los usuarios interesados. Estos hallazgos confirman que el sistema inteligente cumple con los requisitos de funcionamiento y usabilidad necesarios para su implementación exitosa en aplicaciones prácticas dentro de la industria.

Recomendaciones

Para futuros trabajos se sugiere la implementación de este modelo entrenado en combinación con una infraestructura industrial adecuada. Un ejemplo de esto sería el uso de una banda transportadora y una cámara industrial de alta precisión para la detección automática de discos defectuosos en la línea de producción.

Dado que la disponibilidad de imágenes de estos tipos de productos en Internet es limitada, se recomienda recopilar un mínimo de mil imágenes para el entrenamiento del modelo. Esto garantizará una base de datos lo suficientemente robusta para obtener resultados precisos y confiables.

En relación con el desarrollo del algoritmo y la implementación del sistema web, se recomienda el uso de servicios en la nube con mayor capacidad de procesamiento, como Azure Machine Learning o servicios equivalentes de Google Cloud Platform. Esto permitiría un entrenamiento más eficiente y con menor limitación de recursos comparado con Google Colab, que fue utilizado en este trabajo.

Por último, para futuros trabajos se sugiere realizar la recopilación y entrenamiento del modelo utilizando imágenes capturadas en un entorno menos controlado. Esto ayudará a que el modelo sea más robusto y pueda adaptarse mejor a las condiciones reales de producción, donde pueden presentarse variaciones en la iluminación y la posición de los discos.

Referencias

- [1] S. Ferrándiz, «Apenas 30% de empresas que cumplen con estándares de calidad y exportación son mypes | Economía | La República». Accedido: 31 de octubre de 2024. [En línea]. Disponible en: <https://larepublica.pe/economia/2023/11/23/apenas-30-de-empresas-que-cumplen-con-estandares-de-calidad-y-exportacion-son-mypes-1462041>
- [2] P. M. Segovia, «Inspección de Metales con Inteligencia Artificial», JG Automotive. Accedido: 6 de mayo de 2024. [En línea]. Disponible en: <https://jgautomotive.com/inspeccion-metales-inteligencia-artificial/>
- [3] BCRP, «NOTAS DE ESTUDIOS DEL BCRP», Banco Central de Reserva del Perú, Lima, Perú, 21, 2024. Accedido: 8 de abril de 2024. [En línea]. Disponible en: <https://www.bcrp.gob.pe/docs/Publicaciones/Notas-Estudios/2024/nota-de-estudios-21-2024.pdf>
- [4] Weerg, «¿Qué es y para qué sirve el aluminio? Características y propiedades». Accedido: 23 de abril de 2024. [En línea]. Disponible en: <https://www.weerg.com/es/guias/aluminio-que-es-propiedades-caracteristicas>
- [5] Ministerio della Salute, «Campaña informativa sobre el uso correcto del aluminio en la cocina». Accedido: 17 de noviembre de 2022. [En línea]. Disponible en: https://www.salute.gov.it/portale/news/p3_2_6_1_1.jsp?id=140&lingua=italiano&menu=campagne&p=dacampagne
- [6] Agencia para Sustancias Tóxicas y el Registro de Enfermedades (ATSDR), «Resumen de Salud Pública: Aluminio (Aluminum) | PHS | ATSDR», ATSDR. Accedido: 6 de mayo de 2024. [En línea]. Disponible en: https://www.atsdr.cdc.gov/es/phs/es_phs22.html
- [7] Ministerio de Producción, «Produce “La calidad en las MIPYME es un tema de prioridad nacional”», Gob.Pe. Accedido: 24 de octubre de 2022. [En línea]. Disponible en: <https://acortar.link/ZDkhhb>
- [8] Ministerio de Producción, «Innovación en la industria manufacturera y en las empresas de servicios intensivos en conocimiento», Ministerio de la Produccion, Lima, Perú, 2020. Accedido: 6 de octubre de 2022. [En línea]. Disponible en: <https://acortar.link/UV11OZ>
- [9] Ministero della Salute, «Trova Norme & Concorsi - Normativa Sanitaria». Accedido: 6 de junio de 2024. [En línea]. Disponible en: <https://www.trovanorme.salute.gov.it/norme/dettaglioAtto?id=21659>

- [10] J. N. Soto Ríos, «Clasificador de latas sin barniz interno dentro del proceso de fabricación de envases de aluminio para bebidas», 2021, [En línea]. Disponible en: <http://hdl.handle.net/11371/4231>
- [11] C. A. G. Guailazaca González y V. Hernandez A., «Clasificador de Productos Agrícolas para Control de Calidad basado en Machine Learning e Industria 4.0», *Rev. Perspect.*, vol. 2, n.º 2, Art. n.º 2, jul. 2020, doi: 10.47187/perspectivas.vol2iss2.pp21-28.2020.
- [12] R. A. León León, B. J. Beltran Jara, R. Cruz Saavedra, K. Terrones Julcamoro, A. Torres Verastegui, y M. A. Aponte de la Cruz, «Desarrollo de sistema de visión artificial para control de calidad de botellas en la empresa Cartavio Rum Company», *Ing. Investig. Desarro. I2D*, vol. 19, n.º 1, pp. 17-25, 2019, Accedido: 6 de octubre de 2022. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=8276722>
- [13] G. P. Córdova Jaramillo, «Control de calidad de cerámicos con procesamiento digital de Imágenes para reducir costos», Universidad Tecnológica del Perú, Lima, Perú, 2019. Accedido: 6 de noviembre de 2022. [En línea]. Disponible en: <https://hdl.handle.net/20.500.12867/2391>
- [14] E. A. Ramos Adanaque, «Sistema Inteligente para identificar adecuadamente el mango kent no exportable en el área de muestreo de una empresa agroindustrial de la región Lambayeque», Universidad Santo Toribio de Mogrovejo, Chiclayo, Perú, 2021. Accedido: 24 de octubre de 2022. [En línea]. Disponible en: <http://hdl.handle.net/20.500.12423/3936>
- [15] L. E. La Madrid Távara, «Implementación de un algoritmo de control de calidad para la selección de productos agrícolas utilizando visión artificial», Universidad Nacional Pedro Ruíz Gallo, Lambayeque, Perú, 2019. Accedido: 6 de noviembre de 2022. [En línea]. Disponible en: <https://hdl.handle.net/20.500.12893/4737>
- [16] L. Rouhiainen, *Inteligencia Artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Barcelona: Alienta, 2018. [En línea]. Disponible en: https://www.planetadelibros.com/libros_contenido_extra/40/39307_Inteligencia_artificia1.pdf
- [17] L. J. Sandoval Serrano, «Algoritmos de aprendizaje automático para análisis y predicción de datos», *Revista tecnológica*, n.º 11, p. 5, oct. 2018, Accedido: 18 de noviembre de 2024. [En línea]. Disponible en: <http://redicces.org.sv/jspui/handle/10972/3626>
- [18] APD, «¿Cuáles son los tipos de algoritmos del machine learning?», APD España. Accedido: 14 de noviembre de 2022. [En línea]. Disponible en:

- <https://www.apd.es/algoritmos-del-machine-learning/>
- [19] C. J. Tablada y G. A. Torres, «Redes Neuronales Artificiales», *Rev. Educ. Matemática*, vol. 24, n.º 3, 2021, Accedido: 14 de noviembre de 2022. [En línea]. Disponible en: <https://revistas.unc.edu.ar/index.php/REM/article/view/10280>
- [20] AWS, «¿Qué es una red neuronal?», Amazon Web Services, Inc. Accedido: 14 de noviembre de 2022. [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/neural-network/>
- [21] H. Rodríguez, «Propiedades del aluminio (Al)», National Geographic España. Accedido: 14 de noviembre de 2022. [En línea]. Disponible en: https://www.nationalgeographic.com.es/ciencia/propiedades-aluminio-al_18221
- [22] Inoxidables Victoria, «Disco de aluminio», Inoxidables Victoria. Accedido: 14 de noviembre de 2022. [En línea]. Disponible en: <https://inoxidablesvictoria.com/aluminio/disco-de-aluminio/>
- [23] OECD, «Manual de Frascati 2015: Guía para la recopilación y presentación de información sobre la investigación y el desarrollo experimental». 2018. [En línea]. Disponible en: <https://www.oecd-ilibrary.org/content/publication/9789264310681-es>
- [24] Mccall, J; Richards, P; Walters, G, *Factors in software quality*. New York: The National Technical Information Service, 1977.
- [25] L. A. Yong Varela, «Modelo de aceptación tecnológica (tam) para determinar los efectos de las dimensiones de cultura nacional en la aceptación de las tic», *Revista Internacional de Ciencias Sociales y Humanidades, SOCIOTAM*, vol. XIV, n.º 1, pp. 131-171, 2004, Accedido: 12 de noviembre de 2024. [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=65414107>

Anexos**ANEXO N° 01. ENTREVISTA****Nombre:** Evan Rico Ramos**Cargo:** Administrador de la Empresa**Fecha:** 10/10/2022**1. ¿Qué servicios brinda la empresa?**

Contamos con los servicios de Laminado y Venta de Discos.

2. ¿Cuál es el proceso que se sigue para la obtención de los discos de aluminio?

El proceso empieza con la fundición de aluminio, el cual se hace con aluminio reciclado, producto de esto se obtienen plaquetas de aluminio de 3cm de espesor. Luego, estas plaquetas pasan por diversos procesos hasta obtener el disco de aluminio de las medidas deseadas por los clientes que varían entre 0,9 mm, 1 mm, 1,2 mm y 2 mm.

3. ¿Cuáles son las áreas para la producción de los discos de aluminio?

El proceso empieza por el área de Destrocado (se reduce el espesor de las plaquetas), luego pasan al área de Laminado (salen las láminas de aluminio de acuerdo con el espesor que el cliente solicite), área de Cortado (se cortan las láminas de aluminio de acuerdo con las medidas solicitadas), área de Discado (se cortan las láminas de aluminio en forma de disco), área de Hornado (se recocina los discos de aluminio a 520° para darle elasticidad), posteriormente se hace una inspección rápida de imperfecciones antes de entregar los pedidos a los clientes.

4. ¿Qué problemas presenta actualmente la empresa?

Tenemos reclamos por parte de nuestros clientes por discos de aluminio que llegan defectuosos lo que les causa pérdidas económicas tanto a ellos como a nosotros. De los cuáles 4 de cada 10 sí llegan a comunicarnos su queja.

5. ¿Qué defectos presentan estos discos?

Los principales defectos son porque el disco está “carachoso” (debido a falta de limpieza en el material), “rajado” (debido a que el material está duro), “poroso” (debido a falta de limpieza en el material), “globitos” (debido a que el aluminio está pasado de temperatura).

6. ¿Cómo se realiza la inspección actualmente para revisar los discos antes de la venta?

Se hace una inspección luego que los discos salen del horno y están listos para ser entregados, se hace una inspección visual por un encargado de la empresa sobre algunos discos para determinar si presentan los defectos antes mencionados. Muchas veces al personal encargado se le pasan algunos discos defectuosos ocasionando reclamos posteriores de los clientes.

7. ¿Qué es lo que hacen cuando el cliente tiene reclamos sobre los discos defectuosos?

Se le pide que traiga los discos defectuosos para proceder a cambiarlos, los cuales solamente traen los discos que tenían fallas notorias sin contar con los discos que debido a que ya fueron procesados simplemente ya no los traen o significa un gasto adicional en transporte. Pero muchas veces algunos clientes no lo hacen y simplemente empiezan a buscar otros proveedores.

ANEXO N° 02. Cuestionarios TAM

Evaluación del Sistema Inteligente para la predicción de discos de aluminio de calidad

Objetivo: Recopilar la opinión de los usuarios finales para validar la usabilidad del sistema mediante el modelo de aceptación tecnológica (TAM).

Datos Personales:

- Nombres : _____
- Cargo en la empresa: _____

Cuestionario

Se presentan dos bloques de preguntas sobre Facilidad de Uso Percibida y Utilidad Percibida del sistema inteligente desarrollado, las cuales serán evaluadas en una escala de Likert de 1 a 5.

Por favor, marque con una (X) para cada afirmación en base a tu experiencia con el sistema, teniendo en cuenta la siguiente escala:

1 = Muy en desacuerdo

2 = En desacuerdo

3 = Neutral

4 = De acuerdo

5 = Muy de acuerdo

I. Facilidad de Uso Percibida

Preguntas	1	2	3	4	5
Las opciones de la interfaz están claramente presentadas					
Aprender a utilizar el sistema es sencillo					
La navegación a través de las distintas funciones es intuitiva					
No necesité ayuda adicional para entender cómo usar el sistema					
Los mensajes de error y la retroalimentación son claros y fáciles de entender.					

II. Utilidad Percibida

Preguntas	1	2	3	4	5
El sistema predice correctamente el estado de los discos (buenos o malos)					
El sistema me ayuda a realizar mis tareas de forma más rápida					
El sistema es útil para realizar la clasificación de discos defectuosos.					
El uso del sistema mejora la calidad de mi trabajo					
Recomendaría este sistema a otras personas para predecir el estado de los discos					