



UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
SEDE VIÑA DEL MAR – JOSÉ MIGUEL CARRERA

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
SEDE VIÑA DEL MAR – JOSÉ MIGUEL CARRERA

**APLICACIÓN DE VISION ARTIFICIAL PARA EL DIAGNOSTICO
PREDICTIVO DE NEUMATICOS EN EL AREA DE LA MECANICA
AUTOMOTRIZ.**

Trabajo de Titulación para optar al
Título profesional de INGENIERO EN
MANTENIMIENTO INDUSTRIAL

Alumno:

Fernando Esteban Tapia Rodríguez.

Profesor Guía:

Mg. Ing. Carlos Andrés Baldi González.

Profesional Correferente:

Mg. Ing. Raymi Antonio Vásquez Moreno.



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE
MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título; ☐ Tesis de Postgrado;

Título del trabajo: Aplicación de visión artificial para el diagnóstico predictivo de neumáticos en el área de la mecánica automotriz

Nombre del candidato(a): Fernando Esteban Tapia Rodríguez

Carrera / Grado: Ingeniería en Mantenimiento Industrial

Campus: Casa Central Valparaíso ; Departamento: Mecánica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, _____, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente DEJO CONSTANCIA que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

☒ El trabajo **NO** contiene información que amerite **confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

☐ 6 meses; ☐ 12 meses; ☐ 2 años; ☐ 3 años; ☐ 5 años; ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Carlos Baldi Gonzales

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: _____ ; Firma: _____

Estudiante o Candidato(a): Fernando Tapia Rodríguez

Fecha: _____ ; Firma: _____

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



ÍNDICE DE CONTENIDO

Estos dos artículos que se desarrollaron, se espera que sean enviados a la revista científica RAE (REVISTA DE ATIVOS DE ENGENHARIA).

RESUMEN	5
INTRODUCCION	7
OBJETIVO GENERAL.	8
OBJETIVOS ESPECIFICOS.	8
SIGLAS.....	9
INDICE DE FIGURAS Y TABLAS	10
CAPÍTULO 1: FUNDAMENTOS CONCEPTUALES Y TEORICOS	12
1. Introducción.....	13
2. Fundamentos conceptuales y teóricos.....	15
2.1. Inteligencia Artificial	15
2.2. Machine Learning	15
2.2.1. Aprendizaje Supervisado	16
2.2.2. Aprendizaje No Supervisado	16
2.2.3. Aprendizaje por refuerzo	16
2.3. Deep Learning	16
2.3.1. Redes neuronales recurrentes (RNNs)	17
2.3.2. Redes neuronales generativas adversarias (GANs).....	17
2.3.3. Redes neuronales profundas (DNNs)	18
2.3.3. Redes neuronales convolucionales (CNNs).....	18
2.4. Visión Artificial.....	18
2.5. Neumáticos y normativa asociada	20
2.5.1. Neumáticos de verano	21
2.5.2. Neumáticos de invierno	21
2.5.3. Neumáticos mixtos o all season.....	22
3. Implementación de redes neuronales convolucionales para el procesamiento de imágenes	24
4. Conclusión.....	31



CAPÍTULO 2: INDUSTRIA 4.0 Y CASO DE ESTUDIO	34
5. Introducción.....	35
6. Mantenimiento 4.0 utilizando técnicas de inteligencia y vision artificial	37
6.1. Modelo de gestión de mantenimiento.	37
6.2. Industria 4.0.....	37
6.3. Tecnologías claves del mantenimiento 4.0.....	38
6.3.1. Internet de las cosas (IoT)	38
6.3.2. Integración de sistemas	38
6.3.3. Big data y análisis	38
6.3.4. Simulaciones	38
6.3.5. Robótica.....	39
6.3.6. Tecnología en la nube	39
6.3.7. Manufactura.....	39
6.4. Relación de tecnologías de la industria 4.0 y la vision artificial	39
6.4.1. Big data y análisis.....	39
6.4.2. Internet de las cosas (IoT)	39
6.4.3. Tecnología en la nube	39
6.4.4. Integración de sistemas	39
6.5. La industria 4.0 y su impacto en el mantenimiento predictivo.....	39
7. Implementación del sistema de vision artificial.	40
7.1.Librerías más utilizadas.	40
7.1.1 TensorFlow	40
7.1.2 Keras	40
7.1.3. OpenCV.....	40
7.1.4. Matplotlib	40
7.1.5. NumPy.....	40
7.1.6. Scikit-Learn.....	41
7.1.7. TensorBoar	41
7.2. Análisis de resultados: Explicación del código de vision artificial utilizado.	41
7.3. Propuesta de implementación.....	48
8. Conclusión.....	49



CONCLUSION.....51

BIBLIOGRAFIA 52

CAPITULO 1.....52

CAPITULO 2.....54

RESUMEN

KEYWORDS: INTELIGENCIA ARTIFICIAL, MANTENIMIENTO PREDICTIVO, VISION ARTIFICIAL.

La propuesta unificada se basa en el desarrollo e implementación de un sistema de diagnóstico predictivo orientado al análisis automático del estado de los neumáticos mediante visión e inteligencia artificial. Este sistema fue diseñado con el objetivo de identificar fallas comunes, tales como desgaste irregular, exceso o falta de aire, mala alineación o defectos estructurales, antes de que provoquen daños mayores o comprometan la operación segura del vehículo.

El enfoque técnico se centra en la captura de imágenes mediante cámaras instaladas en puntos estratégicos del entorno operativo del vehículo, especialmente en zonas de alto tránsito de unidades. Estas imágenes son procesadas utilizando algoritmos de visión artificial basados en redes neuronales convolucionales, previamente entrenadas con un conjunto de datos que incluye imágenes simuladas de distintas condiciones de fallas. El entrenamiento del modelo se realizó mediante herramientas como TensorFlow y Keras, que permiten ajustar la red neuronal para alcanzar un nivel óptimo de precisión en la clasificación de fallas. Durante el desarrollo, se emplearon técnicas de aumento de datos, validación cruzada y monitoreo del aprendizaje mediante gráficos de precisión y pérdida, logrando resultados satisfactorios en las fases iniciales.

Los ensayos realizados con el modelo muestran que es posible lograr una detección efectiva y anticipada de las fallas más frecuentes en neumáticos, contribuyendo a disminuir el margen de error humano y a establecer procesos de mantenimiento más inteligentes. Además, se considera una integración progresiva del sistema en las rutinas de mantenimiento tradicionales, incluyendo la capacitación de personal técnico y el desarrollo de una interfaz amigable para su operación. Esta propuesta apunta a fortalecer la capacidad predictiva dentro del área de la Mecánica Automotriz, modernizando la forma en que se supervisan y mantienen los componentes fundamentales de los vehículos

INTRODUCCION

En la actualidad, la Mecánica Automotriz enfrenta desafíos cada vez más complejos, entre ellos, la necesidad de contar con sistemas de mantenimiento más eficientes y precisos. Dentro de este escenario, los neumáticos representan un componente crítico cuya falla puede derivar en altos costos operativos, detenciones inesperadas y riesgos de seguridad. A pesar de los avances en el monitoreo manual, este sigue siendo un proceso expuesto a errores humanos y a limitaciones de tiempo, lo cual deja margen para fallas no detectadas a tiempo.

En este contexto, surge una propuesta que busca aprovechar los beneficios de la inteligencia y la visión artificial para dar un paso más hacia el mantenimiento predictivo. A través del uso de cámaras de alta resolución, procesamiento de imágenes y redes neuronales convolucionales (CNN), se plantea un sistema capaz de analizar el estado de los neumáticos de manera automatizada, identificando patrones de desgaste o posibles defectos sin necesidad de intervención directa. Este sistema no solo tiene el potencial de detectar fallas antes de que se conviertan en un problema mayor, sino que también se alinea con las exigencias de la Industria 4.0, que impulsa la digitalización e integración tecnológica en todos los procesos mecánicos.

La presente propuesta no solo aborda los aspectos técnicos del desarrollo de un sistema inteligente para la detección de fallas, sino que también considera su aplicabilidad en ambientes reales, proyectando su implementación de forma gradual y eficiente. Se trata de una visión moderna de la mecánica automotriz, en la que el análisis de datos y la automatización se transforman en aliados para mejorar la seguridad, reducir costos y extender la vida útil de los componentes vehiculares.



OBJETIVO GENERAL.

Desarrollar una propuesta de sistema de diagnóstico predictivo basado en visión e inteligencia artificial para analizar el estado de los neumáticos en flotas de buses, utilizando redes neuronales convolucionales que permitan anticipar fallas y optimizar los procesos de mantenimiento en el área de la Mecánica Automotriz.

OBJETIVOS ESPECIFICOS.

- Diseñar una arquitectura de red neuronal convolucional capaz de identificar patrones de desgaste en neumáticos a partir del procesamiento automatizado de imágenes obtenidas mediante cámaras de alta resolución.
- Implementar un modelo de entrenamiento basado en datos simulados de fallas en neumáticos, utilizando herramientas de inteligencia artificial como TensorFlow y Keras para mejorar la precisión del diagnóstico predictivo.
- Evaluar la efectividad del sistema mediante análisis de desempeño técnico como precisión, pérdida y matriz de confusión, con el fin de validar su aplicabilidad en entornos reales de mantenimiento automotriz.



SIGLAS

IA: Inteligencia artificial

ML: Machine Learning

DL: Deep Learning

RNNs: Redes Neuronales Recurrentes

GANs: Redes Neuronales Generativas Adversarias

DNNs: Redes Neuronales Profundas

CNNs: Redes Neuronales Convolucionales

MTT: Ministerio de transporte y telecomunicaciones

D.S: Decreto Supremo

DG: Defecto Grave

FC: Fully Connected

SGD: Descenso De Gradiente Estocástico

MGM: Modelo de gestión de Mantenimiento

IoT: Internet de las cosas

DTD: Defecto en tren delantero



INDICE DE FIGURAS Y TABLAS

Figura 1.Subconjuntos de la inteligencia artificial. 15

Figura 2. Matriz con pixeles blanco, valor 255. 19

Figura 3. Matriz con pixeles negros, valor 0. 19

Figura 4. Matriz con escale de grises, valor entre [0 - 255]. 19

Figura 5. Matrices representativas RGB. 20

Figura 6. Neumático de verano 21

Figura 7. Neumático de invierno 22

Figura 8. Neumático mixto o all season 22

Figura 9. Características principales neumáticos 23

Figura 10. Referencia de capas de una CNN 25

Figura 11. Referencia de filtro 26

Figura 12. Referencia operación de convolución..... 26

Figura 13. Referencia de imagen de salida de la capa convolucional. ... 27

Figura 14. Referencia capas pooling y flattening..... 27

Figura 15. Modelo de gestión de mantenimiento..... 37

Figura 16. Pilares claves de la industria 4.0 38

Figura 17. Simulación de falla: Defecto en tren delantero (DTD) 41

Figura 18. Simulación de falla: Exceso de aire..... 42

Figura 19. Simulación de falla: Mal alineado. 42

Figura 20. Simulación de falla: Poco aire..... 43

Figura 21. Simulación de condición: Estado normal del neumático. 43

Figura 22. Librerías utilizadas..... 44

Figura 23. Librerías utilizadas..... 44

Figura 24. Arquitectura de la red neuronal..... 45

Figura 25. Compilación de la red neuronal. 45

Figura 26. Gráfico Perdida v/s épocas. 46

Figura 27. Gráfico Precisión v/s épocas. 46



Figura 28. Matriz de confusión. 47

Figura 29. Referencia de la disposición de las cámaras. 48

Tabla 1. Descripción de las características del neumático.....23

Tabla 2. Resumen de las referencias (Fuente: Elaboración propia). 36

CAPÍTULO 1: FUNDAMENTOS CONCEPTUALES Y TEORICOS

Article

APLICACIÓN DE VISION ARTIFICIAL PARA EL DIAGNOSTICO PREDICTIVO DE NEUMATICOS EN EL AREA DE LA MECANICA AUTOMOTRIZ.

Fernando Esteban Tapia Rodriguez¹, Carlos Andrés Baldi González², and Raymi Antonio Vásquez Moreno³.

- 1 Universidad Técnica Federico Santa María, Valparaíso, Chile; Fernando.tapiar@sansano.usm.cl
- 2 Universidad Técnica Federico Santa María, Valparaíso, Chile; Carlos.baldi@usm.cl
- 3 Universidad de Chile, Santiago, Chile; Raymi.vasquez@usm.cl

Resumen: Este artículo presenta una propuesta para la aplicación de un sistema de inteligencia y visión artificial, para el diagnóstico predictivo de neumáticos en la mecánica automotriz. El objetivo principal de la solución es optimizar los procesos de mantenimiento mediante estaciones de monitoreo equipadas con cámaras de alta precisión que capturan imágenes de los neumáticos en condiciones específicas. Estas imágenes son procesadas mediante redes neuronales convolucionales (CNN) para identificar patrones de desgaste y detectar fallas de manera anticipada. Esta tecnología permitiría reducir los costos operativos, mejorar la seguridad y minimizar los tiempos de inactividad de equipos, lo que beneficiaría tanto a la empresa como a los usuarios. La propuesta también contempla la integración del sistema en los procedimientos de mantenimiento existentes, así como el entrenamiento del modelo con datos reales y la capacitación del personal involucrado. A través de esta iniciativa, alineada con los principios de la Industria 4.0, se sientan las bases para la modernización de las operaciones, mejorando la seguridad y calidad del servicio ofrecido en el futuro.

Citation: To be added by editorial staff during production.

Academic Editor: Firstname
Lastname

Received: date
Revised: date
Accepted: date
Published: date



Copyright: © 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Keywords: Inteligencia Artificial; Mantenimiento predictivo; Visión Artificial; Monitoreo basado en condición

1. Introducción

En la actualidad, el sector del transporte enfrenta grandes desafíos relacionados con el mantenimiento y la seguridad de sus flotas. La eficiencia operativa y la reducción de tiempos de inactividad por fallas no planificadas son aspectos críticos para garantizar la continuidad del servicio y la satisfacción de los usuarios. Uno de los elementos más vulnerables en las flotas de transporte son los neumáticos, cuya supervisión y mantenimiento adecuados son esenciales para prevenir accidentes y evitar altos costos por fallas imprevistas.

En este contexto, las nuevas tecnologías, como la inteligencia artificial (IA) y, en específico, un sistema de visión artificial, han comenzado a desempeñar un papel fundamental en la optimización de

procesos de mantenimiento predictivo. Estos sistemas permiten analizar grandes cantidades de fotografías y detectar problemas antes de que se conviertan en fallas críticas, lo que mejora la seguridad y reduce las interrupciones operativas. El presente proyecto surge a partir de la necesidad de automatizar tareas del área de la mecánica automotriz para así aumentar la seguridad en sus operaciones y mejorar la calidad de los viajes. Para abordar esta necesidad, se propone la implementación de un sistema automatizado para la inspección y el diagnóstico anticipado de fallas en los neumáticos de su flota. La visión artificial se presenta como una herramienta clave para lograr este objetivo, al proporcionar un análisis constante y preciso de los neumáticos, lo que permitirá anticipar problemas y optimizar las actividades de mantenimiento, beneficiando tanto a la empresa como a los pasajeros [1].

La metodología empleada en este proyecto se basa en el análisis de requisitos específicos, incluyendo los tipos de neumáticos utilizados y las condiciones operativas típicas. Posteriormente, se desarrolla un sistema de visión artificial configurando cámaras de alta resolución para capturar imágenes de los neumáticos, y se diseñan algoritmos de IA para procesar estas imágenes y detectar patrones de desgaste y posibles fallas. Una vez desarrollado el sistema, se integra en los procesos de mantenimiento existentes, permitiendo una supervisión continua y la generación de alertas tempranas sobre el estado de los neumáticos. La validación del sistema se realiza mediante pruebas en un entorno controlado para verificar la precisión y eficacia, seguido de una implementación gradual en toda la flota. Finalmente, se ofrece formación y capacitación al personal de mantenimiento y conductores para asegurar el uso efectivo del nuevo sistema.

Con la implementación de este sistema, se espera lograr una serie de beneficios significativos, como la reducción de costos al identificar y corregir problemas de manera preventiva, la mejora en la seguridad al disminuir el riesgo de accidentes y la optimización del mantenimiento mediante un sistema predictivo que asegure que los neumáticos se mantengan en condiciones óptimas de operación. Todo esto contribuirá a una mayor satisfacción de los usuarios, al mejorar la calidad de los viajes y reducir las interrupciones operativas.

En resumen, la integración de tecnologías avanzadas como la IA y la visión artificial en los procesos de mantenimiento representan un paso crucial hacia la modernización y optimización de sus operaciones, en línea con las tendencias de la Industria 4.0 [2].

2. Fundamentos conceptuales y teóricos

2.1. Inteligencia Artificial

La inteligencia artificial o IA, es un área de la informática que busca crear algoritmos capaces de realizar acciones las cuales requieren inteligencia humana, como lo sería el aprendizaje, razonamiento, toma de decisiones, entre otras.




Figura 1.Subconjuntos de la inteligencia artificial.

Como se puede observar en la Figura 1 la inteligencia artificial es un conjunto que se compone del Machine Learning o ML y del Deep Learning o DL, es importante considerar que cada uno de estos términos tiene un propósito y definición asociado, lo que se procederá a explicar a continuación [3].

2.2. Machine Learning

El ML a diferencia de la programación regular en la cual se conocen las entradas y posteriormente se escribe una línea de código la cual se espera que procese los datos de entradas y obtener un resultado de salida. Esta información que se forme es algo conocido o esperado por el usuario, en cambio, el ML requiere datos de entrada y salida, en una etapa posterior llamada fase de entrenamiento procesa toda la información que se le entrega y crea una estructura de código con lo aprendido y este va realizando ajustes para ir mejorando las respuestas que se entregan al usuario, en pocas palabras el Machine Learning se basa en reconocer patrones en los datos que se le entregan y poder realizar predicciones con el aprendizaje automático [4].

Este tiene una variedad de aplicaciones en el mundo como lo sería en la industria automotriz con los vehículos autónomos, en los sistemas de recomendaciones personalizadas casos como Netflix o Spotify y también sirve para realizar análisis en clientes que asisten a una tienda, para hacer grupos en base a su comportamiento y segmentarlos.

Otra aplicación que se le puede dar sería en el ámbito industrial en donde se proporcionarían datos numéricos o imágenes de algún equipo o sistema para que el modelo busque y logre detectar anomalías, identificar patrones o clasificarlas [5].

Existen tres tipos de Machine Learning, los cuales se explicarán a continuación.

2.2.1. *Aprendizaje Supervisado*

En este se debe tener conjuntos de datos con características y etiquetas con las respuestas correctas. Un ejemplo sería un modelo para predecir el precio de una casa, en este caso los datos deben ser consiste a la acción a realizar se deben entregar ubicación, cantidad de baños, número de habitaciones, si hay piscina o no, etc. Lo que hace es generar relaciones entre todas las variables presentes, en la fase de entrenamiento y predecir valores de las casas, lo fundamental de esto es que el modelo que se entreno sirve para realizar nuevas predicciones de casas que no se conocen. Esto también se puede aplicar en imágenes con modelos de clasificación en donde te puede diferenciar entre un perro y un gato.

2.2.2. *Aprendizaje No Supervisado*

A diferencia del anterior los datos son sin etiquetas, por lo que el modelo deberá buscar patrones y realizar las relaciones correspondientes. En modo de ejemplo tomaremos en que se mencionó en el punto 1.1 con respecto a los clientes de una tienda, acá se deben tener datos de cada uno de los clientes y agruparlos según su acción realizada en la tienda compra, no compra o realiza compras online, en base a esto se realizan campañas de mercado por cada grupo de clientes identificados [6].

2.2.3. *Aprendizaje por refuerzo*

Acá se pone a un agente para que aprenda en un ambiente por medio de acciones y retroalimentación, este por cada acción que realice se le van dando o quitando puntos numéricos en base a si lo que hizo esta bien o mal y el algoritmo buscara ajustarse solo para realizar o tomar decisiones las cuales le sumen puntos, pero cada acción que se haga va a realizar cambios en el ambiente por lo que la retroalimentación es constante y por cada acción se debe reevaluar [7].

2.3. *Deep Learning*

El Deep Learning (DL) es un subconjunto de lo que es el Machine Learning (ML), con la gran diferencia que el DL se basa en redes neuronales artificiales, las cuales están compuestas por capas de neuronas artificiales interconectadas. Estas redes pueden aprender a reconocer patrones complejos en los datos mediante el aprendizaje automáticos, el cual sería similar a lo que se mencionó en el ML, puede ser supervisado o no supervisado [8].

Las principales diferencias que se pueden tener entre el Machine Learning y el Deep Learning sería la estructura de código con la cual se escribe, en el ML el algoritmo suele ser más lineal y mucho más simple de hacer, se deben elegir el algoritmo adecuado según las necesidades (regresión lineal, regresión logística, arboles de decisiones, etc.) a diferencia del DL que se centra en estructuras más complejas, en donde se involucran arquitecturas de redes neuronales artificiales y se deben definir funciones de perdidas, activación ,formas de optimizar, etc.

En el Deep Learning existen variedades de arquitecturas de redes neuronales las cuales se adaptan a las tareas que se requieren hacer según el usuario, las más conocidas serían las siguientes [9].

2.3.1. *Redes neuronales recurrentes (RNNs)*

Estas están diseñadas para trabajar con datos secuenciales, como lo serían el texto o audios, son ampliamente utilizadas para tareas de reconocimiento de voz, traducción de idiomas, etc. Algunos equipos donde se suelen utilizar RNNs sería Siri y Google Translate [10].

2.3.2. *Redes neuronales generativas adversarias (GANs)*

Se componen por dos redes que se enfrentan, una generadora y otra discriminadora, la primera se encarga de crear datos que no se diferencien de los reales, debe ir mejorando constantemente su habilidad para la generación de los datos, en cambio la segunda debe distinguir entre los datos reales y los generados, por lo que al igual que la anterior también debe evolucionar su capacidad para decidir cuáles son datos reales y los generados. Un ejemplo sería la generación de imágenes que parecieran ser tomadas por humanos para retratos de personas que no existen [11].

2.3.3. *Redes neuronales profundas (DNNs)*

Son herramientas claves para el aprendizaje automático y el procesamiento de datos, estas son capaces de realizar tareas por sí misma, trabajan con múltiples capas las cuales procesan la información, es decir, que los datos de salida de una capa se vuelven en los datos de entrada de la siguiente capa. En modo de ejemplo tendríamos la conducción autónoma en la cual se debe procesar información de sensores, para tomar decisiones en tiempo real sobre la navegación y control de vehículo [12].

2.3.3. *Redes neuronales convolucionales (CNNs)*

Estas están especialmente diseñadas para el procesamiento de datos en imágenes, esto es debido a la gran capacidad de aprender y extraer características relevantes de manera automática y eficiente, estas buscan emular la visión humana. Ejemplos de estas serían la clasificación de imágenes, detección de objetos, y reconocimiento facial, toso estos ejemplos mencionados se pueden efectuar en tiempo real o mediante fotos o imágenes [13].

2.4. *Visión Artificial*

La visión artificial es un área de la inteligencia artificial, que permite a las computadoras extraer información importante en base a imágenes, videos o alguna otra entrada. Lo que permite que pueda recomendar acciones en base a la información aprendida. La inteligencia artificial busca dotar a los ordenadores con la inteligencia humana, la visión artificial les permitirá ver, observar y entender.

Esta funciona de manera semejante a lo que es la visión humana, pero tiene una gran desventaja debido a que las personas tiene toda una vida de aprendizaje lo que permite saber por medio de los ojos cuando algo está mal, en otra posición, si se está moviendo o si tiene alguna forma diferente, la visión artificial debe aprender como realizar todas estas acciones mediante muchos datos de entradas y algoritmos.

Lo principal que se utiliza para el proceso de entrenamiento de un código de visión artificial son las dos tecnologías mencionadas anteriormente el Machine Learning y el Deep Learning, en específico una red neuronal convolucional (CNN) [14].

Antes de seguir avanzando se debe profundizar en un tema fundamental para la visión artificial, los datos de entrenamientos en específico las imágenes.

El concepto imagen puede variar dependiendo del área en cuestión, un fotógrafo puede tener un significado distinto al de una persona, ya que probablemente representante cosas con otro significado, en el campo de la informática y en la visión artificial, tiene un concepto que puede llegar a ser muy diferente para los mencionados anteriormente.

Las imágenes en la visión artificial son representadas por matrices de variados tamaños, por ejemplo: de 6×6 , 12×12 , 24×24 , etc. Estas pueden ser del tamaño que se estime conveniente para la etapa de entrenamiento. Cada cuadradito que se puede apreciar en base al tamaño de la matriz se le denomina píxel, por ende, los ejemplos anteriores se debiesen escribir de esta manera: 6×6 pixeles, 12×12 pixeles, 24×24 pixeles. Con esto se busca llegar a siguientes, cada píxel de la imagen puede tomar un valor de entre $[0 - 255]$, esto va a representar el color de dicho píxel, si este tiene un numero 0 el píxel tomara el color negro y si tomase el valor 255 seria de color blanco, por lo tanto, los valores que se encuentran entre el intervalo $[0 - 255]$ representan lo que se conoce como la escale de grises.




Figura 2. Matriz con pixeles blanco, valor 255.




Figura 3. Matriz con pixeles negros, valor 0.




Figura 4. Matriz con escale de grises, valor entre [0 - 255].

Esto es fundamental al momento de hacer el código de la red neuronal, debido a que se deben entregar la forma de las imágenes de entrada para empezar el aprendizaje, o también conocido como `input_shape`, el cual tiene una forma de tensor multidimensional con la siguiente estructura (10 x 10 x 1), representando el largo, ancho y el canal, en este caso el numero uno es para identificar que se trabajara con imágenes en blanco y negro, pero en esto

profundizaremos más adelante. Pero no solo se puede aprender con imágenes en escala de gris, los colores son de suma importancia para ciertos casos, esto se representa como RGB en base a los colores primarios Rojo, Verde y Azul, al igual que lo mencionado anteriormente, estos son representados por matrices que toman intervalos de [0 - 255], pero en estos casos si el píxel toma un valor de 255 este representara el color en si rojo, verde o azul. Ya que en simples palabras se encuentran apiladas en una estructura tridimensional, en donde si se varían los valores de cada píxel se irán obteniendo todos los colores conocidos como secundarios.




Figura 5. Matrices representativas RGB

Los datos a colores se representan de forma similar que los datos a escala de gris como tensor multidimensional (10 x 10 x 3), en vez de tener como canal el número 1 se introduce con el número 3, con estos se establece que los datos de entrada son a color.

La etapa de aprendizaje llega a variar cuando se trata de los colores, si bien el entrenar la red neuronal con datos a escala de grises, genera una reducción de los datos provocando que los tiempos para aprender sean menores. Pero se puede llegar a perder detalles fundamentales, para este proceso. Algún ejemplo donde el color no es importante seria: Diferenciar entre perros y gatos, marcas de vehículos, identificar texturas, etc. Pero de igual forma el color es fundamental cuando se trata de alguna otra tarea, ya que, se pueden obtener más detalles de las imágenes y, por ende, aprende de mejor manera la red neuronal, pero esto implica un mayor peso en los datos y un mayor tiempo de aprendizaje para la CNN, algunos ejemplos: Clasificar maderas por su color, diferenciar entre frutas y verduras, etc. En modo de conclusión del concepto de imagen, el decidir que la red neuronal aprenda en base a datos a escala de gris o a color va a depender solamente de lo que se necesite hacer con el modelo de CNN, ya que con ambos tendrás buenos resultados.

Una CNN lo que hará en visión artificial es que mirará los datos y aprenderá a diferenciar entre una imagen y otra, desglosándolas en los pixeles a los cuales se le asigna una etiqueta, con la cual podrá realizar predicciones con respecto a lo que está viendo, para ir realizando ajustes e ir mejorando continuamente en lo que va aprendiendo, para así mejorar la exactitud de sus predicciones [15].

Los neumáticos son de suma importancia en cualquier tipo de vehículo que los requiera, estos influyen en la seguridad y en el rendimiento. Su función principal es soportar el peso del automóvil, pero esto va más allá de esto, son responsables de proporcionar la tracción, estabilidad y frenado. Esto sumado con la experiencia del conductor proporciona seguridad a este y a los acompañantes.

De estos existen una gran variedad, cada uno se adapta a la condición de conducción y al ambiente climático en donde se pretende circular el vehículo. Presentándose en tres tipos principales de clasificación.

2.5.1. *Neumáticos de verano*

Este tipo de neumáticos están contruidos con un caucho más firme en comparación a los de invierno, lo que permite un mejor control y agarre en autopistas con temperaturas mayores a 7 °C, esto se transforma en mayor seguridad y reduciendo la distancia de frenado, debido a su deformación reducida, estos neumáticos presentan una menor resistencia al rodar, lo que implica una mejora en el consumo de combustible, menos ruidos y un menor desgaste. Al tener un ancho mayor, este aumenta su contacto en la carretera, por lo que mejora su agarre en general. Este al verse a temperaturas menores a los 7°C todas las cualidades positivas mencionadas pierden efecto.



Figura 6. Neumático de verano

2.5.2. *Neumáticos de invierno*

En los casos, de temperaturas inferiores a los 7°C se recomienda, realizar los cambios de neumáticos de verano por los de invierno, ya que, estos están diseñados para tener un mayor agarre en situaciones climáticas como la lluvia, nieve o hielo. Cuentan con un mayor porcentaje de caucho natural, y por esta razón no se endurecen con estas condiciones medio ambientales, conservando su flexibilidad y una mayor adherencia a las calles con baja temperatura. Su banda de rodadura presenta una mayor cantidad de surcos y son más profundos, lo que aumenta la evacuación del agua, estos son precisamente para aumentar la seguridad, evitando que el conductor pierda el control del vehículo [16].



Figura 7. Neumático de invierno

2.5.3. Neumáticos mixtos o all season

Estos son ideales para lugares en donde las condiciones climáticas no varían demasiado, estos destacan tanto en condiciones de invierno como de verano, presentado las cualidades de cada uno de los mencionados anteriormente en los puntos 2.5.1 y 2.5.2 adaptándose a las situaciones meteorológicas.



Figura 8. Neumático mixto o all season

En modo de resumen, cada neumático se diseña para adaptarse a las variadas condiciones climáticas y según las necesidades de conducción, optimizando el rendimiento y la seguridad del vehículo según sean la estación.

Las condiciones climáticas, no son las únicas características en las que se deben prestar atención al momento de comprar neumáticos, se deben entender conceptos de medidas y tamaño de neumático, como también, índice de carga y velocidad, estas especificaciones se pueden encontrar en el flaco del neumático en una nomenclatura que se mostrara a continuación [17].



Figura 9. Características principales neumáticos

Tabla 1. Descripción de las características del neumático.

Características	Descripción
195	Indica el ancho del neumático en milímetros.
55	Es un porcentaje proporcional del flanco con respecto al ancho
R	Tipo de construcción, en este caso Radial.
16	Diámetro interior del neumático y el de la llanta pulgadas.
87	Índice de carga.
V	Índice de velocidad.

Los neumáticos radiales son los más utilizados, esto se debe a su construcción interna, la cual se caracteriza por pequeñas lonas de metal que se distribuyen desde el interior hacia afuera y existen los tubulares o los conocidos con cámara de aire, estos ya no son utilizados en vehículos, pero se suelen utilizar en bicicletas.

Cada índice ya sea el de carga o velocidad depende netamente del uso que se le dé al vehículo por lo que se debe indagar al momento de adquirir neumáticos.

El mantenimiento a estos componentes es crucial para garantizar seguridad y rendimiento, por lo que se recomienda un monitoreo periódico verificando profundidad de la banda de rodadura, grietas, presión de inflado, realizar rotaciones, etc. Esto junto a otras recomendaciones de mantenimiento y conducción ayudan a prolongar la vida útil de estos activos [18].

2.6. Normativa Chilena asociada a neumáticos

Todo vehículo terrestre que circula por el territorio de Chile circula por medio de los neumáticos, anteriormente se habló a grandes rasgos de estos componentes, pero estos deben cumplir con ciertos reglamentos para que puedan transitar por las carreteras de Chile de manera óptima y garantizando la seguridad del conductor, pasajeros y otros conductores.

Existen una diversidad de vehículos los cuales se pueden clasificar en base a la licencia de conducir que estos requieren, existen diversos tipos de licencias, pero en este caso nos centraremos en la siguiente:

- Clase A: Se basa en el transporte de pasajeros, ya sea taxis, ambulancias, buses, camiones simples o articulados destinados al transporte de carga.

En Chile el ministerio de transportes y telecomunicaciones (MTT) se encarga de fiscalizar y promulgar decretos supremos y leyes del tránsito. De misma manera existe instalaciones autorizadas por el MTT las cuales realizan inspecciones de manera periódica a diversos vehículos motorizados, con el fin de que cumplan estándares de seguridad y ambientales para su uso en carreteras, esta es la función de las plantas de revisión técnicas nos centraremos en los manuales de interpretación de resultados para vehículos clase A en específico en el apartado de inspección visual en la zona exterior del vehículo ruedas u neumáticos este se basa en el D.S. 59/1987 MTT y el D.S 212/1997 MTT [19].

Acá se establecen profundidades mínimas de la banda de rodadura la cual no debe ser menor a 2 [mm], esta se optime realizando seis mediciones a los dos surcos más próximos de la línea central de la banda de rodadura, éstas se deben realizar en todos los neumáticos, si en al menos tres de las mediciones realizadas se encuentra valores menores a 2 [mm] se considerara como defecto grave (DG) lo que provocara que el vehículo tenga que salir de servicio, lo mismo aplica para neumáticos redibujados, recauchados, desgaste no uniforme en la banda de rodadura y los cuales presenten deformaciones que comprometan las telas internas o cortes en los flancos de este, lo cual también implicaría un DG por lo que sacaría al vehículo de circulación, hasta que logre resolver el problema.

Lo mencionado anteriormente se basa en la capacidad de transporte de pasajeros y en el tonelaje por eje, por lo que aplica tanto para buses, minibuses y taxi buses lo cuales se centran netamente en el traslado de pasajeros, esto aplica para todo el territorio nacional. Este tipo de buses dedicados al transporte minero se establece bajo una normative minera en donde a sus neumáticos les corresponde una profundidad de seguridad de 3 [mm] [20].

3. Implementación de redes neuronales convolucionales para el procesamiento de imágenes.

Redes neuronales convolucionales y visión artificial

Anteriormente se mencionó de manera breve y por separado los conceptos de redes neuronales convolucionales (CNN) y visión artificial, ahora se procederá a explicar el cómo se pueden relacionar estos entre sí para lograr un modelo de predicción de fallas en neumáticos. Las CNN poseen una arquitectura de construcción la cual se compone de múltiples capas, para así generar una salida la cual sería la predicción esperada, pero para realizar una correcta interpretación de los datos de entrada, se necesitan imágenes de calidad, para así aumentar la exactitud del modelo.




Figura 10. Referencia de capas de una CNN

1.1. Capa de entrada

La capa de entrada, siendo la primera en las redes neuronales convolucionales (CNNs), no tiene capacidad de aprendizaje ni incluye neuronas, pero cumple un rol fundamental. Su función principal es recibir los datos en bruto, como imágenes, videos, audios o textos, y dar inicio al proceso de extracción de características ("feature extraction"). Esto implica redimensionar y preparar los datos para que puedan ser analizados en las siguientes etapas de la red. Aunque las tareas específicas de esta capa dependen de la arquitectura de la red, generalmente incluyen funciones esenciales como las mencionadas a continuación.

Normalización de los datos: Se encarga de garantizar la consistencia en la escala y distribución de los datos, lo que contribuye a acelerar el proceso de entrenamiento.

Preprocesamiento: Incluye técnicas como el *Data Augmentation* (aumento de datos), así como recortes y redimensionamientos. Estas técnicas buscan asegurar uniformidad en los tamaños de los datos de entrada y, al mismo tiempo, aumentar su diversidad para enriquecer el entrenamiento.

Propagación hacia adelante (*forward propagation*): Consiste en transferir los datos a través de la red para que sean procesados en las diferentes capas [22].

1.2. Capa convolucional

Esta capa es alimentada en base a las imágenes de las cuales requiero extraer patrones, esto con el fin de obtener un mapa de características o feature map, lo que representara la presencia de bordes, texturas o formas en las imágenes de entrada.

La obtención de estas características las realiza mediante la utilización de un filtro o kernel, el cual es una matriz que recorre cada píxel de la imagen realizando operaciones matemáticas denominadas convoluciones, las cuales son un conjunto de multiplicaciones y sumas, el resultado obtenido de esta operación es una característica para una nueva imagen.




Figura 11. Referencia de filtro

Como se puede apreciar en la figura 12 el proceso de la obtención de un feature map se compone en tres etapas. La primera en donde tenemos el píxel de referencia el cual dependerá de la imagen en cuestión, ya que, el valor de cada uno de estos pixeles dependerá netamente de los colores que se encuentren en esa posición en específico, la segunda etapa es la del filtro estos valores son en base a lo que se requiera detectar, no son totalmente aleatorios, pero van cambiando según la necesidad.




Figura 12. Referencia operación de convolución.

Las matrices construidas anteriormente son en base a la figura 12 para lograr explicar la operación matemática de la convolución. Lo que se hace es lo siguiente:

$$(-1*3) + (0*0) + (1*1) + (-2*2) + (0*6) + (2*2) + (-1*2) + (0*4) + (1*1) = -3$$

Este resultado se ubica en una posición para ir construyendo lo que es el mapa de características, los demás valores que se pueden ver con un signo de interrogación en la figura 12 serán calculados cuando el filtro pase nuevamente por esa posición y así completar la matriz resultante con los valores correspondientes, para así llegar a la tercera y última etapa en donde el proceso de aprendizaje termina y se genera una imagen idéntica a la de entrada.



Figura 13. Referencia de imagen de salida de la capa convolucional.

Como es posible apreciar en la figura 13 la imagen generada, se encuentra un poco distorsionada, pero si el ojo humano logra identificar a una mujer el sistema de visión artificial también lo lograra apreciar [23].

1.3. Capa pooling y flattening

Las CNNs incluyen capas de pooling y flattening, como se muestra en la figura 12, para procesar y preparar los datos para análisis posteriores. Las capas de pooling reducen las dimensiones espaciales de los mapas de características para disminuir la carga computacional, utilizando operaciones fijas como el Max pooling, que selecciona el valor máximo de una ventana de datos. Luego, las capas de flattening transforman estos mapas multidimensionales en vectores unidimensionales que se pasan a las capas completamente conectadas.




Figura 14. Referencia capas pooling y flattening.

2.5. Capas densas o fully connected (FC)

Las capas densas, también conocidas como fully connected (FC), se encuentran en las últimas etapas de una red neuronal y están compuestas por neuronas que se conectan con todas las neuronas de las capas circundantes. Su función es integrar las características extraídas previamente, permitiendo construir representaciones más avanzadas y complejas. Estas capas son fundamentales para llevar a cabo el procesamiento final de la información.

2.6. Capa de salida

La capa de salida, ubicada al final de una CNN, tiene como propósito tomar decisiones fundamentadas en las características que la red ha extraído y aprendido. Es indispensable que todas las neuronas de esta capa estén completamente conectadas con las neuronas de la capa fully connected anterior.

2.6.1. Loss function

En las CNN, la función de pérdida o función de costo se utiliza para medir de manera matemática la discrepancia (pérdida) entre los valores predichos por la red y los valores reales. Entre las funciones de pérdida más utilizadas se encuentran Softmax y SVM. Otras opciones incluyen el error cuadrático medio, el error absoluto medio, entre otras.

2.6.2. Backpropagation y gradientes

La retro propagación, o backpropagation, es un proceso de dos fases que implica calcular los gradientes a partir de la pérdida generada en la salida del modelo (durante el paso hacia adelante) y ajustar los parámetros del modelo, como los pesos y sesgos, con base en estos gradientes. Este método utiliza los gradientes para actualizar los parámetros de manera que se minimice la pérdida y se optimice la precisión. En primer lugar, se determina el gradiente de la pérdida con respecto a la salida de la capa final. Luego, se propaga este gradiente hacia atrás a través de las capas del modelo, aplicando la Regla de la Cadena en cada nodo, hasta obtener el gradiente de la pérdida con respecto a cada parámetro del modelo.

2.6.3. Optimizadores

Los optimizadores son algoritmos diseñados para ajustar los parámetros de las CNNs utilizando los gradientes calculados y la tasa de aprendizaje (learning rate) durante el proceso de retro propagación. Cada optimizador emplea un conjunto de reglas específicas para realizar estas actualizaciones. Entre los optimizadores más utilizados se encuentran el Descenso de Gradiente Estocástico (SGD), RMSProp y Adam. En particular, Adam y NAG suelen ser considerados como opciones altamente eficientes para el ajuste de parámetros en modelos complejos [22].

2.7. Aplicaciones de CNNs y visión artificial

En la actualidad los sistemas de inteligencia y la visión artificial están generando una nueva era digital, con la interacción de estas dos tecnologías para automatizar, mejorar la toma de decisiones y resolver problemas complejos que se pudiesen presentar. Existen diversos campos de aplicación de estos sistemas cada día es mayor, a continuación, se presentarán diferentes industrias en donde esta tecnología ha sido aplicada.

En el área de las inversiones en donde la aplicación de inteligencia artificial impacto de manera positiva ayudando en el comportamiento de los empleados y mejorando la relación entre los altos cargos de la organización [24].

El campo de la educación culinaria la visión artificial garantizo el cumplimiento del uso de los uniformes de los alumnos, lo cual es de suma importancia para cumplir los estándares de higiene, seguridad y profesionalismo, con este sistema se busca identificar los componentes principales del uniforme, como lo son las chaquetas, delantales, sombreros y los pantalones de chef [25].

Utilizada en la industria de la ingeniería química para determinar el tamaño de partículas de procesos industriales los cuales trabajan con producto granulado húmedo en específico celulosa microcristalina [26].

En el ámbito de la mecánica industrial desde un punto de vista técnico el área de producción utiliza la visión artificial para detectar desgaste en las herramientas de mecanizado y ánodo de rayos X rotativos [27], también otro ejemplo es el de predecir la precisión de la rugosidad en la superficie de perfiles cilíndricos de aluminio, esto con el fin de aumentar la calidad del material [28].

La visión artificial se logró aplicar para detectar el crecimiento urbano, esto mediante la utilización de imágenes satelitales, para así reconocer información del cambio por el uso de suelos y la distribución regional de los asentamientos humanos [29].

En la construcción se utiliza para el automatizado del control de calidad en el proceso de inspección para las barras de acero, las cuales son utilizadas en las estructuras de hormigón [30].

Como se puede apreciar, se han presentados diversos ejemplos de utilización de inteligencia y visión artificial, en diversos campos tanto de la mecánica, seguridad en el trabajo, construcción, estudio de crecimiento urbano, educación culinaria e ingeniería química. Esto con el fin de revolucionar la forma en la que los problemas se abordan y así mejorar la comprensión de las cosas que nos rodean, buscando beneficios que puedan aportar en el mundo.

Con esto se busca plantear un nueva aplicación para lo que sería la inteligencia y visión artificial, en el campo de la mecánica automotriz, en específico con la flota de activos de la empresa de transportes CVU, principalmente se planea instalar estaciones de monitoreo de los neumáticos de los buses, los cuales prestan servicios de traslado a diferentes empresas y a sus respectivos campamentos mineros, por lo que están sometidos a diferentes condiciones ya sea climático o por irregularidades en el camino, estas pueden afectar la estructura del neumático, lo cual puede provocar fallas imprevistas, afectando la credibilidad de la empresa en temas de calidad y seguridad tanto para sus choferes y pasajeros. Esto puede generar pérdidas de contratos impacto en la economía de la empresa CVU.

Las estaciones de monitoreo estarían equipadas con cámaras, estas deben apuntar a los neumáticos delanteros del bus de la figura 11, en específico a la banda de rodadura, debido a que, esta zona expresa mucho mejor las condiciones actuales de lo que es el tren delantero del equipo, estas estarán apuntando en forma diagonal, por lo que el operador del bus deberá situarse

en un punto específico totalmente detenido, una vez en esta condición se deberá girar la dirección totalmente a la derecha y después en su totalidad a la izquierda, mientras el operador realiza esta acción la cámara estará tomando ráfagas de fotos, estas posteriormente serán analizadas por código de inteligencia artificial, para así lograr detectar fallas con las que se entrenó el sistema, la idea es utilizar estas mismas imágenes capturadas como imágenes para entrenar lo que sería la CNNs para ir aumentando la precisión de la predicción y llegar a un punto en donde prácticamente el error de la inteligencia artificial sea cero.

4. Conclusión.

Este trabajo ha permitido explorar cómo la inteligencia artificial, y en particular la visión artificial, puede convertirse en una herramienta valiosa y accesible para talleres mecánicos pequeños y medianos que operan en el área de la mecánica automotriz. A través del estudio de conceptos como redes neuronales convolucionales y procesamiento de imágenes, se ha evidenciado que tecnologías antes reservadas para grandes industrias hoy pueden ser adaptadas y aplicadas en espacios más modestos, donde la eficiencia y la rapidez en el diagnóstico marcan la diferencia.

La posibilidad de utilizar sistemas inteligentes para detectar fallas en los neumáticos, por ejemplo, representa un gran avance para estos talleres, ya que les permitiría ofrecer un servicio más preciso, rápido y confiable, sin depender exclusivamente de la inspección visual tradicional. Además, al automatizar ciertos procesos, se reducirían los márgenes de error humano y se podrían prevenir fallas antes de que se conviertan en problemas mayores, lo que también beneficia al cliente final.

Aunque el sistema aún no se ha implementado, la propuesta desarrollada en este estudio demuestra que no es necesario contar con una infraestructura compleja ni con grandes inversiones para comenzar a incorporar tecnologías de este tipo. Más bien, se trata de una oportunidad para modernizar los métodos de trabajo, mejorar la competitividad del taller y ofrecer un valor agregado que responda a las nuevas exigencias del sector automotriz.

En definitiva, este trabajo plantea una visión práctica y alcanzable de cómo la inteligencia artificial puede integrarse a los procesos de mantenimiento automotriz, incluso en contextos de menor escala. Lo que antes parecía exclusivo de grandes empresas ahora puede comenzar a formar parte del día a día de muchos talleres mecánicos, marcando un camino hacia una mecánica más moderna, preventiva y tecnológica, sin perder el enfoque humano que caracteriza a estos espacios.

Referencias

- [1] Crespo Márquez A. (2007). The maintenance management framework. Models and methods for complex systems maintenance. London: Springer Verlag. <https://books.google.cl>
- [2] Turconi, G., Ventola, G., González-Prida, V., Parra, C., Crespo, A. (2022). A Literature Review on Lean Manufacturing in the Industry 4.0: From Integrated Systems to IoT and Smart Factories. In: Verma, J.K., Saxena, D., González-Prida, V. (eds) IoT and Cloud Computing for Societal Good. EAI/Springer Innovations in Communication and Computing. <https://easychair.org>
- [3] Ana González Muñiz. (2018). Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (Deep learning) al análisis y mejora de eficiencia de procesos industriales. <https://www.researchgate.net>
- [4]Javier Mora Pineda. (2022). Predictive models in health based on machine Learning. <https://doi.org/10.1016/j.rmcl.2022.11.002>
- [5] David Kauchak. (2016). Neural Networks. <https://doi.org/10.1016/j.neunet.2024.106392>
- [6] Claudio Aracena, Fabián Villena, Felipe Arias, Jocelyn Dunstan. (2022). Applications of machine Learning in healthcare. <https://doi.org/10.1016/j.rmcl.2022.10.001>
- [7] Sierra-García, J. E, Santos, M. (2021). Neural networks and reinforcement learning in wind turbine control. <https://scispace.com>
- [8] Hugo Chanampe, Silvana Aciar, Martin de la Vega, José Luis Molinari Sotomayor, German Carrascosa, Alejandro Lorefice. (2019). Modelo de Redes Neuronales Convolucionales Profundas para la Clasificación de Lesiones en Ecografías Mamarias. <http://sedici.unlp.edu.ar/handle/10915/77381>
- [9] Ke Chang, Xinna Yu, Wei Ren, Xianmin Jin, Yafei Zhang, Hui Wang. (2024). Artificial vision system based on porosity heterojunction for in-sensor processing and dynamic trace extraction. <https://doi.org/10.1016/j.device.2024.100598>
- [10] José A. Ruz Hernández, Edgar N. Sánchez, Dionisio A. Suárez. (2008). Algoritmo de entrenamiento óptimo para diseñar una memoria asociativa de Diagnóstico de fallas. [https://doi.org/10.1016/S1697-7912\(08\)70129-8](https://doi.org/10.1016/S1697-7912(08)70129-8)
- [11] Guangqi CHEN. (2024). Prospects, Challenges and Guidelines for Practical Deep Learning in Geoengineering. <https://doi.org/10.1016/j.ige.2024.10.001>
- [12] Álvaro Artola Moreno. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python. <https://idus.us.es>
- [13] Manlio Massiris, Claudio Delrieux, J. Álvaro Fernández. (2018). Detección de equipos de protección personal mediante red neuronal convolucional yolo. <http://dx.doi.org/10.17979/spudc.9788497497565.1022>
- [14] Iván García, y Víctor Caranqui. (2015). Artificial vision and fields of application. <http://dx.doi.org/10.32645/26028131.76>
- [15] M. C. José Jaime Esqueda Elizondo. (2002). Fundamentos de Procesamiento de Imágenes. <https://www.researchgate.net>
- [16] <https://www.eleconomista.es> [Accedido en Diciembre 2024].
- [17] <https://www.autonocion.com> [Accedido en Diciembre 2024].
- [18] <https://www.ancosev.org> [Accedido en Diciembre 2024].
- [19] <https://www.bcn.cl> [Accedido en Diciembre 2024].
- [20] <https://www.prt.cl> [Accedido en Diciembre 2024].
- [22] <https://keepcoding.io> [Accedido en Diciembre 2024].
- [23] Valeria Beatriz Angulo De La Fuente. (2024). Detección Temprana De Fallas En Cintas Transportadoras Mediante Visión Computacional Y Deep Learning. <https://repositorio.uchile.cl>
- [24] Xi Zhong, Jianquan She, Xiaojie Wu. (2024). Tech for social good: Artificial intelligence and workplace safety. <https://doi.org/10.1016/j.techsoc.2024.102745>
- [25] Ismael Castillo-Ortiz, Carmen Villar-Patino, Elizabeth Guevara Martínez. (2024). Computer vision solution for uniform adherence in gastronomy schools: An artificial intelligence casa study. <https://doi.org/10.1016/j.ijgfs.2024.100997>
- [26] Pieranto Facco, Andrea C. Santomaso, Massimiliano Barolo. (2017). Artificial vision system for particle size characterization from bulk materials. <https://doi.org/10.1016/j.ces.2017.01.053>

-
- [27] Jannis Walk, Niklas Kühlb, Michael Saidani, Jürgen Schatte. (2023). Artificial intelligence for sustainability: Facilitating sustainable smart product-service systems with computer vision. <https://doi.org/10.1016/j.jclepro.2023.136748>
- [28] Karthikeyan S, Subbarayan M R, Mathan Kumar P, Radha Krishnan Beemarajd, Sivakandhan C. (2022). Computer vision-based surface roughness measurement using artificial neural network. <https://doi.org/10.1016/j.matpr.2021.09.314>
- [29] Laura Cano Salinas, Rodrigo Rodríguez Laguna, José René Valdez Lazalde, Otilio Arturo Acevedo Sandoval y Rosa Icela Beltrán Hernández. (2016). Monitoring of urban growth in the state of Hidalgo using Landsat images. <https://doi.org/10.14350/rig.52339>
- [30] Yurii Kardovskyi, Sungwoo Moon. (2021). Artificial intelligence quality inspection of steel bars installation by integrating mask R-CNN and stereo vision. <https://doi.org/10.1016/j.autcon.2021.103850>

CAPÍTULO 2: INDUSTRIA 4.0 Y CASO DE ESTUDIO

concreta a los desafíos actuales del mantenimiento, ofreciendo una mirada hacia el futuro de la gestión inteligente en el transporte. [20]

Tabla 2. Resumen de las referencias (Fuente: Elaboración propia).

Article	Similarities	Differences	Research Gap
Carlos Alberto Parra Márquez., Crespo Márquez A. (2015): Ingeniería de Mantenimiento y fiabilidad aplicada a la gestión de activos.	Plantea el mantenimiento como factor estratégico en la gestión de activos, en línea con el enfoque técnico adoptado,	No aborda herramientas de inteligencia artificial ni visión artificial.	La investigación realizada hace un cambio de enfoque, llevando el punto de vista estratégico a un terreno práctico, mediante el uso de un sistema basado en visión artificial.
Guillermo Beltrán Cardoso., Jorge Parra Michel., Leobardo Ceja Bravo., Sandra Olivares Bautista., Rafael Martínez Peláez. (2021): ¿Qué es industria 4.0?: elementos clave de la industria 4.0.	Define los elementos de la Industria 4.0, incluyendo tecnologías como IA, big data, y sistemas inteligentes.	Es un enfoque conceptual que no desarrolla casos prácticos ni modelos específicos.	si bien ambas investigaciones desarrollan un marco conceptual basado en la industria 4.0, en los artículos se abordan directamente el diseño y uso de un sistema de IA y visión artificial para la inspección predictiva a neumáticos del área automotriz.
Fujitsu. (2019): El Mantenimiento Predictivo en la Industria 4.0.	Propone el mantenimiento predictivo como parte del avance hacia la industria inteligente, lo cual es concordante con los artículos.	No presenta aplicaciones desarrolladas con procesamiento de imágenes ni modelos de CNN.	La investigación realizada aplica un sistema el cual entrena y se valida mediante el uso de imágenes reales, generando métricas las cuales permiten evaluar su impacto en caso de ser llevado a terreno.
Iván García, y Víctor Caranqui. (2015): Artificial vision and fields of application.	Introduce el concepto de visión artificial y sus áreas de aplicación, lo que sustenta la base técnica de los artículos.	No detalla el uso de CNN ni casos específicos de transporte.	Los artículos buscan desarrollar un sistema operativa basado en visión artificial, con el fin de detectar fallas mediante la captura de imágenes reales de neumáticos de vehículos del sector de la Mecánica Automotriz.
Xi Zhong, Jianquan She, Xiaojie Wu. (2024): Tech for social good: Artificial intelligence and workplace safety.	Coincide con los artículos en el uso de IA como herramienta para mejorar la seguridad operativa.	Su enfoque se centra en seguridad laboral en entornos industriales, sin tratar el diagnóstico mecánico.	La investigación realizada propone una arquitectura funcional utilizando herramientas de la visión e inteligencia artificial, con el fin de automatizar el diagnóstico de fallas y demostrar que se puede llevar a una aplicación real.
Guangqi CHEN. (2024): Prospects, Challenges and Guidelines for Practical Deep Learning in Geoen지니어ing.	Aborda los desafíos prácticos del Deep Learning, lo cual está relacionado con el entrenamiento de redes neuronales como se realiza en los artículos.	Aplicación enfocada en geoen지니어ing, sin relación directa con el diagnóstico mecánico o transporte.	Los artículos desarrollan el uso de Tensorflow, keras, etc. Para el entrenamiento de un modelo de CNN, el cuál busca ser aplicado a imágenes capturadas en tiempo real y así realizar un análisis de parámetros.
José A. Ruz Hernández, Edgar N. Sánchez, Dionisio A. Suárez. (2008): Algoritmo de entrenamiento óptimo para diseñar una memoria asociativa de Diagnóstico de fallas.	Aborda el entrenamiento de modelos de diagnóstico de fallas, temática común con los artículos.	No utiliza imágenes ni visión artificial; su aproximación es abstracta y algorítmica.	Si bien ambas investigaciones proponen un enfoque a la IA, el trabajo realizado completamente esa línea, mediante una solución basada en CNN, la cual utiliza imágenes reales para optimizar el diagnóstico predictivo en el sector automotriz.
Manlio Massiris, Claudio Delrieux, J. Álvaro Fernández. (2018): Detección de equipos de protección personal mediante red neuronal convolucional yolo.	Comparte el uso de redes neuronales convolucionales para la detección visual automatizada.	Aplicación centrada en elementos de seguridad personal en espacios laborales, sin vínculo con vehículos o neumáticos.	La investigación realizada traslada esta tecnología al sector automotriz, aplicando IA y visión artificial, para evaluar métricas como exactitud, pérdida y matriz de confusión, para así tener un análisis del funcionamiento de este modo de aplicación.

La tabla 1 resume investigaciones que aplican inteligencia y visión artificial. Si bien comparten enfoques y objetivos similares, pocas abordan su uso en el sector de la Mecánica Automotriz. Esto revela una oportunidad de investigación en ese ámbito específico.

6. Mantenimiento 4.0 utilizando técnicas de inteligencia y vision artificial

6.1. Modelo de gestión de mantenimiento.

Este modelo surge para mejorar y organizar la forma en que se realiza el mantenimiento, ya sea, en la industria o en empresas. Como principal objetivo es lograr que el mantenimiento sea más eficiente, efectivo y siempre considerando la mejora continua.



Figura 15. Modelo de gestión de mantenimiento.

Como se puede observar en la figura 1 este modelo es representado en un ciclo cerrado, esto permite hacer ajuste y mejoras en la gestión si es necesario a lo largo del tiempo, así se puede asegurar menos fallas, menores costos y aumentar la vida útil de los activos.

Si bien este modelo presenta fases fundamentales para el diseño de planes de mantenimiento, programas, definir estrategias y objetivos, etc. La principal fase, de mayor importancia es la 8 que hace referencia a “Implementación del proceso de mejora continua y adopción de nuevas tecnologías”, esta frase se puede dividir en dos partes esenciales lo que es, la mejora continua en donde es vital estudiar resultados en busca de oportunidades de mejora, capacitar al personal para que puedan mejorar sus prácticas y la que se relaciona con la segunda parte de la frase la que es aplicar las nuevas tecnologías, como lo sería, el uso de sensores, inteligencia artificial, etc.

Un término fundamental de la fase 8 del MGM es el e-Maintenance, que en simple palabras es aprovechar el internet y las tecnologías digitales, para así lograr mejorar el mantenimiento, monitoreando en tiempo real, diagnosticar problemas antes de que se convierta en una falla grave y predecir cuándo es necesario realizar mantenimiento.[1]

6.2. Industria 4.0.

Este término de industria 4.0 o cuarta revolución industrial surge en respuestas a las nuevas tecnologías digitales, transformando todos los aspectos de la vida al combinar estas herramientas con lo físico y lo digital, consigo traerá nuevas oportunidades como desafíos para las personar y empresas [2],

como en su respectiva época apareció lo que es la primera revolución industrial con el uso de la máquina de vapor para mecanizar la producción, posterior apareció la electricidad y la producción en masa, también conocida como la segunda revolución industrial y el concepto tercera revolución industrial donde se introducen los temas de la informática y la automatización, para finalmente llegar a nuestra época en donde las fábricas buscan integrar tecnologías como inteligencia artificial, internet de las cosas, big data, robótica, etc.[3] Con esto se busca que las maquinas, sistemas y personas trabajen de manera interconectada, para así lograr una mejora en eficiencia y que nos permita no solo optimizar recursos, sino que también cambie la forma en que se toman decisiones y gestionar recursos.[4]

6.3. *Tecnologías claves del mantenimiento 4.0*




Figura 16. Pilares claves de la industria 4.0

En la figura 2 se pueden observar la diversidad de tecnologías que forman parte de la industria 4.0 y que están revolucionando el mantenimiento, gracias a esta nueva tecnología es posible prevenir las fallas antes de que se conviertan en un problema mayor, esto permite optimizar recursos y aumentar la eficiencia

6.3.1. *Internet de las cosas (IoT)*

Esto hace referencia a la conexión como maquinas o sensores a internet por lo tanto pueden enviar información en tiempo real.

6.3.2. *Integración de sistemas*

En este punto se busca la conexión entre diferentes programas y dispositivos para que trabajen en conjunto y de manera coordinada.

6.3.3. *Big data y análisis*

Acá la cantidad de datos es vital para encontrar patrones y lograr predecir o anticipar fallas por lo que el uso de inteligencia artificial para el análisis de los datos es vital.

6.3.4. *Simulaciones*

Son pruebas virtuales que permiten ver como funcionaria algo antes de aplicarlo a la realidad.

6.3.5. *Robótica*

Son maquinas inteligentes diseñadas para realizar tareas que normalmente las haría una persona, pero este las realizaría de forma más precisa y rápida.

6.3.6. *Tecnología en la nube*

Acá la información se almacena en un lugar en específico del internet y se encuentra disponible en todo momento para quien la necesite.

6.3.7. *Manufactura*

Es básicamente el proceso de fabricar cosas, desde celulares hasta autos.[5]

6.4. *Relación de tecnologías de la industria 4.0 y la vision artificial*

Antes se mencionaron brevemente los pilares claves del mantenimiento 4.0, si bien todos son vitales solo algunos se pueden llegar a relacionar con la inteligencia y vision artificial.

6.4.1. *Big data y análisis*

Al tener una gran cantidad de imágenes en este caso de los neumáticos de los buses, estos posteriormente serán analizados para encontrar patrones y así poder detectar fallas de manera anticipada. [6]

6.4.2. *Internet de las cosas (IoT)*

Al tener cámaras como objeto de captura de las fotos de los neumáticos, estas se encuentran conectadas a una red para enviarlas en tiempo real aun sistema de análisis. [7]

6.4.3. *Tecnología en la nube*

Si en procesamiento de imágenes y el almacenamiento de estas se guardan en un servidor en la nube, en vez de un computador personal, todos los involucrados en el proyecto tendrían un acceso completo en donde se compartirían resultado entre el equipo en tiempo real. [8]

6.4.4. *Integración de sistemas*

Para el correcto funcionamiento, es necesario conectar distintos componentes, ya sea, el código de análisis de imagen y la base de datos de las respectivas fotos, al encontrarse conectadas se logra que trabajen de manera simultánea. [9]

6.5. *La industria 4.0 y su impacto en el mantenimiento predictivo*

El mantenimiento predictivo es una estrategia en donde mediante el monitoreo, almacenamiento y recopilación de datos en tiempo real de variables como presiones, temperaturas, vibraciones, etc. Esto permite mediante el análisis de estos datos detectar fallas de manera temprana antes de que ocurran, contrario a lo que es el mantenimiento correctivo el cual se enfoca en reparar la falla cuando ya ocurrió y el mantenimiento preventivo que es mediante un calendario fijado principalmente por los fabricantes.

La industria 4.0 tiene un impacto fundamental para lo que es el mantenimiento predictivo, ya que, debido a las nuevas tecnologías muchas maquinas o equipos ya vienen con sensores para tener un monitoreo en tiempo real de parámetros principales de funcionamiento, de esta manera todos los datos que se recopilan en tiempo real se pueden analizar con el uso de inteligencia artificial, en donde se pueden detectar patrones y prever la falla antes de que se presente, así mismo se puede optimizar el proceso de planificación de mantenimientos y buscar prolongar la vida útil de los activos.

El aprovechamiento de estas nuevas tecnologías nos permite mejorar la eficiencia, reduce costos, permite prevenir fallas, mayor seguridad y optimiza los mantenimientos. [10]

7. Implementación del sistema de vision artificial.

Como se ha mencionado anteriormente el mantenimiento predictivo se apoya fuertemente con tecnologías claves de la industria 4.0 como es la inteligencia y vision artificial, ahora es necesario llevar estos conceptos desde la teoría a la práctica y así tener una aplicación en concreto. En este caso se hablará del desarrollo de un sistema el cual es capaz de detectar fallas mediante el análisis de imágenes de manera automática. Para logra este propósito se utilizaron un conjunto to de herramienta y librerías de programación, las cuales permitieron entrenar el modelo de inteligencia artificial, procesar imágenes y obtener resultados. A continuación de manera simple se explicarán las librerías más utilizadas en el desarrollo de este tipo de sistemas.

7.1.Librerías más utilizadas.

7.1.1 TensorFlow

Es una plataforma que permite crear y entrenar modelos de inteligencia artificial, este es la base para construir el modelo de red neuronal de análisis de imágenes de neumáticos. [11]

7.1.2 Keras

Funciona como una interfaz más sencilla que trabaja sobre TensorFlow, esta facilita la construcción de modelos de IA sin la necesidad de escribir tanto código. Así agilizando el desarrollo. [12]

7.1.3. OpenCV

Es una librería especializada en trabajar con imágenes. Se utilizó para leer, modificar y preparar las imágenes antes de que fueran analizadas por el modelo. [13]

7.1.4. Matplotlib

Permite crear gráficos y visualizar resultados. Es útil para observar cómo va aprendiendo el modelo, mostrando curvas de precisión, pérdida y otros datos durante el entrenamiento. [14]

7.1.5. NumPy

Se usa para manejar datos en forma de matrices, algo esencial cuando se trabaja con imágenes y modelos de IA, ya que estos transforman las imágenes en números para poder analizarlas. [15]

7.1.6. *Scikit-Learn.*

Ofrece herramientas para organizar y dividir los datos, algo importante para entrenar el modelo con una parte del conjunto de imágenes y probarlo con otra. [16]

7.1.7. *TensorBoar*

Es una herramienta visual que permite monitorear en tiempo real cómo va el entrenamiento del modelo. Ayuda a entender mejor el proceso y tomar decisiones sobre ajustes. [17]

Todas estas librerías trabajaron en conjunto y cumplieron distintos roles dentro del proyecto. Algunas se encargaron del procesamiento de imágenes, otras ayudaron a construir el modelo de inteligencia artificial, y también hubo herramientas que sirvieron para monitorear su funcionamiento. Al usarlas en conjunto, fue posible llevar a la práctica los conceptos de mantenimiento predictivo e Industria 4.0 de forma concreta y funcional.

7.2. *Análisis de resultados: Explicación del código de vision artificial utilizado.*

Con anterioridad en el punto 3.1 se mencionaron de manera general las principales librerías que se utilizan en la confección de un código de inteligencia y vision artificial, en los siguientes puntos se procederá a mostrar partes fundamentales para la arquitectura del programa y que permite que sea funcional, comenzando desde las librerías utilizadas, variables planteadas para la CNN, matriz de confusión, etc.

En primera instancia es importante mencionar antes de la explicación de las partes fundamentales del código, que datos le vamos a entregar a la red neuronal. Se le entregaran fotos de neumáticos en donde se simulan diferentes modos de fallas, que se pueden llegar a presentar en la banda de rodadura de estos, la simulación se realizó mediante la utilización de cinta adhesiva en ciertos puntos característicos del neumático.



Figura 17. Simulación de falla: Defecto en tren delantero (DTD)

En la figura 17 se refleja el desgaste que puede producirse cuando hay problemas en el tren delantero del vehículo, como desajustes o piezas dañadas. El patrón que se observa en el neumático no es uniforme, y suele aparecer un desgaste irregular que puede afectar el desempeño y la seguridad del vehículo.



Figura 18. Simulación de falla: Exceso de aire.

La figura 18 muestra un neumático con una presión superior a la recomendada. En este caso, el desgaste se concentra principalmente en el centro de la banda de rodadura, lo cual puede provocar una menor adherencia al pavimento y una conducción menos segura.



Figura 19. Simulación de falla: Mal alineado.

La condición en la figura 19, se presenta cuando las ruedas no están correctamente alineadas, provocando que el neumático se desgaste de forma dispareja, generalmente más de un lado que del otro. Es una falla común que, si no se corrige, puede derivar en un desgaste prematuro y afectar la estabilidad del vehículo.



Figura 20. Simulación de falla: Poco aire.

En la figura 20 se simula un neumático con presión de aire insuficiente. El desgaste tiende a concentrarse en los bordes del neumático, y en muchos casos puede generar un sobrecalentamiento o incluso una falla estructural. Es una de las fallas más frecuentes en la operación diaria de buses.



Figura 21. Simulación de condición: Estado normal del neumático.

En la figura 21 se incluye una categoría que representa un neumático en condiciones óptimas: con la presión adecuada, sin signos de desgaste irregular ni daños visibles. Esta clase es fundamental como referencia para que el modelo pueda distinguir claramente entre lo que se considera una condición segura y una falla potencial.

Las figuras anteriores forman parte fundamental para comenzar el entrenamiento de la red neuronal, ya que, con estas será capaz de identificar características fundamentales, para así lograr aprender, si bien es probable que esta pueda generar confusiones entre las imágenes, este error se alguna manera se puede mejorar.

Dicho esto, se comenzará a explicar el código que se utilizó para el entrenamiento.

```
from keras.models import Sequential, Model
from keras.layers import Conv2D, MaxPool2D, Dense, Flatten, Dropout, BatchNormalization, Input
from keras.optimizers import Adam
from keras.callbacks import TensorBoard, ModelCheckpoint
from tensorflow.keras.utils import to_categorical

import os
import numpy as np
from keras.preprocessing import image
from keras.applications.imagenet_utils import preprocess_input, decode_predictions
from keras.applications.vgg16 import VGG16
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from sklearn.utils import shuffle
from sklearn.model_selection import train_test_split
import cv2
import matplotlib.pyplot as plt
%matplotlib inline
```

Figura 22. Librerías utilizadas.

Como se puede apreciar en la figura 3, se presentan las librerías que se utilizaron para la construcción y el entrenamiento de la red neuronal, la cual se enfoca en la clasificación de imágenes, principalmente se utiliza Keras y TensorFlow para crear el modelo, manejar las capas de la red, optimizar el entrenamiento y hacer el preprocesamiento de las imágenes. Es de importancia mencionar que se utilizó VGG16, esta es una red neuronal preentrenada y muy popular que se utiliza debido a su simplicidad, profundidad y su capacidad para aprender características robustas, la que la hace ideal para trabajar con grandes conjuntos de datos. Se utilizan librerías de herramientas como Scikit-Learn para dividir los datos en entrenamiento, validación y prueba, OpenCV para el procesamiento de las fotos, y Matplotlib que es fundamental para visualizar los gráficos y entender como está funcionando la red.

```
width_shape = 250
height_shape = 250
num_classes = 5
epochs = 100
batch_size = 32

train_data_dir = '/content/NeuCamCVU/NeuCamCVU/Train'
validation_data_dir = '/content/NeuCamCVU/NeuCamCVU/Val'
```

Figura 23. Librerías utilizadas.

Si se observa en la figura 23 se podrán apreciar ciertas variables que logran ser de suma importancia para el entrenamiento de la

red neuronal. Se establece el tamaño que tendrán las imágenes en este caso de 250x250 pixeles, representando su largo y ancho. El modelo deberá clasificar las imágenes en 5 categorías diferentes, este se configuro para realizar 100 ciclos (epochs) para así procesar los datos en grupos de 32 imágenes a la vez (batch size). Como último se dan las rutas en donde se almacenan las imágenes de entrenamiento y validación, estas son necesarias para que el modelo aprenda y también para que vaya comprobando su desempeño.

```
model = Sequential()

inputShape = (height_shape, width_shape, 3)
model.add(Conv2D(32,(3,3), input_shape=inputShape))
model.add(Conv2D(32,(3,3)))
model.add(MaxPool2D())

model.add(Conv2D(64,(3,3)))
model.add(Conv2D(64,(3,3)))
model.add(Conv2D(64,(3,3)))
model.add(MaxPool2D())

model.add(Flatten())
model.add(Dense(64,activation='relu'))
model.add(Dense(32,activation='relu'))
model.add(Dense(num_classes,activation='softmax', name='output'))
```

Figura 24. Arquitectura de la red neuronal.

En la figura 24 se aprecia la red neuronal convolucional (CNN) que se utilizó y construyo para el entrenamiento con las imágenes, también se puede apreciar que aparecen variables presentadas en la figura 4, el modelo se arma de forma secuencial agregando varias capas de convolución, esta permite detectar características en las imágenes, seguida de una capa MaxPooling, esta reduce el tamaño de la información para hacer que el proceso sea más eficiente. Después de varias capas convolucionales, se utiliza una capa Flatten, esta convierte la información en un vector. Finalmente se agregan capas densas o totalmente conectadas para que el modelo pueda aprender a clasificar correctamente.

```
model.compile(loss='categorical_crossentropy',optimizer='adadelta',metrics=['accuracy'])
model_history = model.fit(
    train_generator,
    epochs=epochs,
    validation_data=validation_generator,
)
```

Figura 25. Compilación de la red neuronal.

En esta figura ya se logra observa la parte más importante, acá se compila el modelo y todo la mencionado en las figuras anteriores se une para comenzar con el entrenamiento, de misma forma se define como calcular errores, como se debe corregir así mismo y la métrica que se utilizara para evaluar el rendimiento. El modelo aprenderá mediante varias repeticiones (100 epochs) usando los dataos de entrenamiento y en cada paso evalúa su progreso con otro grupo de imágenes que no ha visto (validación). Esto permite al modelo ajustarse de manera progresiva hasta lograr una buena precisión.

El proceso de entrenamiento de datos es algo que toma tiempo, lo principal y más importante son los gráficos que se pueden obtener, ya que, estos se mostraran que tan bien se comporta el

modelo de la red neuronal, a continuación, se mostraran graficas que son de suma importancia para entender si realmente está haciendo lo que se requiere.




Figura 26. Gráfico Perdida v/s épocas.

En la figura 26 se logra apreciar el grafico de la función de perdida, se puede observar que la perdida al inicio es sumamente alta, por lo que el modelo no está haciendo buenas predicciones, pero lo más importe es ver como esta va disminuyendo a lo que el entrenamiento avanza, esto nos indica que el modelo va aprendiendo. También es importante ver la relación entre estas dos líneas, debido a que podría indicar si hay un sobreajuste, en este caso no, ya que, ambas líneas disminuyen a la par y no se observa que alguna vaya en aumento, las dos líneas en un punto dado se estabilizan.




Figura 27. Gráfico Precisión v/s épocas.

En este caso la figura 27 representa la precisión del modelo, este es el porcentaje de predicciones correctas que realiza el modelo, se puede observar que el modelo al principio del entrenamiento la precisión es baja lo que es válido, debido a que el modelo aun no aprende nada, pero al igual que el caso anterior es ver el comportamiento a lo que avanza el entrenamiento, se ve que la precisión aumenta por lo que esté está aprendiendo a clasificar, la tendencia de estas dos líneas, en este caso ambas precisiones tienden a aumentar y luego se estabilizan, aunque en este caso la validación se estabiliza un poco antes que la de entrenamiento, esto es normal y aceptable hasta cierto punto.

En modo de conclusión las gráficas muestran que el modelo está aprendiendo bien durante el entrenamiento. Se puede ver que la pérdida va bajando y la precisión va mejorando tanto en los datos de entrenamiento como en los de validación. Aunque la precisión en validación se queda un poco por debajo de la de entrenamiento, eso es completamente normal. No se observa un sobreajuste fuerte, ya que la pérdida en validación no sube bruscamente y la precisión también mejora antes de estabilizarse.




Figura 28. Matriz de confusión.

Una matriz de confusión es una herramienta que se usa en inteligencia artificial para evaluar qué tan bien está funcionando un modelo de clasificación. Básicamente, muestra cuántas veces el modelo acertó y cuántas veces se equivocó al predecir las distintas categorías, comparando las respuestas reales con las que el modelo predijo.

Se puede observar que las clases DTD y Mal alineado logran tener un rendimiento bueno en ambos casos, Exceso de aire logra tener un rendimiento aceptable, Poco aire tiene un rendimiento moderado de aciertos, y en la categoría Normal es donde se presenta un rendimiento sumamente bajo, esto nos indica que el modelo tiene problemas para identificar las imágenes que son de la etiqueta Normal y las confunde en principio con la categoría DTD.

La matriz de confusión te da una idea clara de cómo está funcionando tu modelo, muestra en qué clases acierta y en cuáles se equivoca. Gracias a esta, puedes ver qué categorías le resultan más fáciles de identificar y en cuáles tiene más

problemas. Esta información es muy útil para saber en qué está fallando el modelo y qué podrías ajustar para mejorarlo.

La mejora continua es fundamental para lograr resultados precisos y confiables. Existen diversas estrategias que pueden optimizar el rendimiento del modelo, como la aumentación de datos, que genera variabilidad en el conjunto de entrenamiento, o el ajuste de los hiperparámetros, como la tasa de aprendizaje y el tamaño del batch, que impactan directamente en la velocidad y precisión del entrenamiento. Además, utilizar técnicas de regularización como el dropout o la normalización de los datos puede evitar el sobreajuste y mejorar la capacidad del modelo para generalizar. Es importante también evaluar los resultados mediante métricas como la matriz de confusión, ya que esta proporciona una visión clara de las clases que el modelo está clasificando correctamente y aquellas en las que necesita mejorar. Con estas prácticas, se puede aumentar significativamente la efectividad de los modelos en tareas de visión artificial.

7.3. *Propuesta de implementación.*

Esta idea se propone implementar mediante el uso de dos cámaras, estas se instalarán en puntos clave con el fin de capturar fotografías de las bandas de rodaduras de los buses de la empresa de transporte.




Figura 29. Referencia de la disposición de las cámaras.

Como es posible observar en la figura 29, las cámaras se planean ubicar en los costados de una vía altamente transitada por los activos de la empresa, pero esto no basta, se necesitara ayuda de los operadores de los buses para capturar las fotos, ellos deberán detenerse en un punto del camino y realizar giros mediante el uso del volante, estos giraran a la derecha e izquierda, mientras los choferes realizan esta maniobra las cámaras estas en modo ráfaga para poder capturar la mayor cantidad de fotos posibles, esta ráfaga se planea hacer mediante el uso de un sensor de movimiento, si bien habrán muchas fotos que no servirán para el entrenamiento de la red neural, otras serán fundamentales para el inicio del entrenamiento de esta, por ende, se debe hacer un proceso de limpieza de datos para poder alcanzar un valor de predicción de falla alto.

8. Conclusión.

La propuesta presentada en este artículo demuestra la viabilidad técnica del uso de visión e inteligencia artificiales para el diagnóstico predictivo de neumáticos en buses, alineada con los principios del mantenimiento 4.0. Aunque el sistema aún no ha sido implementado en un entorno real, las pruebas iniciales realizadas con imágenes simuladas y redes neuronales convolucionales ofrecen resultados alentadores que refuerzan el potencial de esta tecnología para transformar la gestión del mantenimiento en empresas de transporte como CVU.

Pensando en la mejora continua, se proyecta que esta propuesta evolucione hacia soluciones aún más avanzadas. Entre las principales líneas de desarrollo futuro se encuentra la incorporación de redes neuronales preentrenada como YOLOv11, lo cual permitiría dejar atrás el uso de fotografías individuales para dar paso al análisis en tiempo real mediante video, incluso en transmisiones en vivo y en directo. Esto reduciría significativamente la dependencia de la intervención humana y permitiría una automatización mucho más robusta y precisa del proceso de diagnóstico. [21]

Además, se sugiere integrar tecnologías complementarias como sensores IoT, almacenamiento en la nube, y procesamiento en el borde (edge computing) para mejorar la velocidad de respuesta y escalabilidad del sistema. Con estos avances, esta propuesta podría consolidarse en el futuro como una herramienta esencial para el mantenimiento predictivo, permitiendo a las empresas no solo anticipar fallas, sino también tomar decisiones estratégicas basadas en datos confiables y en tiempo real. [20]

Referencias

- [1] Carlos Alberto Parra Márquez., Crespo Márquez A. (2015). Ingeniería de Mantenimiento y fiabilidad aplicada a la gestión de activos. <http://dx.doi.org/10.13140/RG.2.2.29363.66083>
- [2] Carlos Parra., Pablo Duque., Félix Pizarro., Andrés Aránguiz., Vicente González Prida., Jorge Parra. (2024). Modelo de gestión de mantenimiento (MGM) optimizado a partir del uso de tecnologías de la industria 4.0. <http://dx.doi.org/10.13140/RG.2.2.10581.03044>
- [3] <https://evtech.cl/industria-y-mantenimiento-4-0/> [Accedido en Abril 2025].
- [4] Guillermo Beltrán Cardoso., Jorge Parra Michel., Leobardo Ceja Bravo., Sandra Olivares Bautista., Rafael Martínez Peláez. (2021). ¿Qué es industria 4.0?: elementos clave de la industria 4.0 <https://www.researchgate.net>
- [5] <https://traction.com> [Accedido en Abril 2025].
- [6] <https://www.edsrobotics.com> [Accedido en Abril 2025].
- [7] Vanessa Alvear., Henry Farinango., Iván Navarrete., Paul Rosero Montalvo., Jorge Noguera., Fabián Cuzme., Diego Peluffo. (2016). Internet de las Cosas y Visión Artificial, Funcionamiento y Aplicaciones: Revisión de Literatura. <http://dx.doi.org/10.29019/enfoqueute.v8n1.121>
- [8] <https://whitestack.com> [Accedido en Abril 2025].
- [9] <https://industrial.ai> [Accedido en Abril 2025].
- [10] Fujitsu. (2019). El Mantenimiento Predictivo en la Industria 4.0. <https://www.clubexcelencia.org>
- [11] <https://www.incentro.com> [Accedido en Abril 2025].
- [12] <https://www.ionos.com> [Accedido en Abril 2025].
- [13] V. M. Arévalo., J. González., G. Ambrosio. (2002). La librería de visión artificial OpenCV aplicación a la docencia e investigación. <https://www.researchgate.net>
- [14] <https://datascientest.com> [Accedido en Abril 2025].
- [15] <https://aprendeconalf.es> [Accedido en Abril 2025].
- [16] <https://www.master-data-scientist.com> [Accedido en Abril 2025].
- [17] <https://www.tensorflow.org> [Accedido en Abril 2025].
- [20] <https://www.sciencedirect.com> [Accedido en Abril 2025].
- [21] <https://docs.ultralytics.com> [Accedido en Abril 2025].
- [22] <https://mcr.es> [Accedido en Mayo 2025].
- [23] <https://ibernova.com> [Accedido en Mayo 2025].

CONCLUSION

La propuesta presentada representa un paso significativo hacia la transformación digital del mantenimiento automotriz, enfocándose en uno de los elementos más críticos del vehículo: los neumáticos. A través de la implementación de un sistema basado en visión artificial y redes neuronales convolucionales, se ha demostrado la factibilidad técnica de anticipar fallas que, de no ser detectadas a tiempo, podrían afectar gravemente la operación y seguridad de una flota.

Los resultados obtenidos a partir de simulaciones, entrenamientos de modelos y pruebas de validación evidencian el potencial de esta tecnología para integrarse en los procesos actuales de mantenimiento. La capacidad de clasificar imágenes con precisión, distinguir entre diferentes tipos de fallas y generar alertas tempranas es un avance concreto hacia un mantenimiento predictivo real y funcional. Si bien aún se requiere una etapa de implementación práctica y validación en terreno, la base técnica ya ha sido establecida, y el camino hacia su consolidación es claro.

En el marco de la Mecánica Automotriz, esta iniciativa se proyecta como una herramienta valiosa para técnicos, supervisores y encargados de flota, permitiendo una gestión más eficiente de los recursos, una reducción en los tiempos de inactividad y una mejora sustancial en la seguridad del transporte. Más allá de lo técnico, esta propuesta refleja una forma distinta de enfrentar los desafíos del mantenimiento: anticiparse en lugar de reaccionar, entender los datos como aliados, y confiar en que la tecnología bien aplicada puede marcar una diferencia real en el rendimiento de los vehículos.

BIBLIOGRAFIA

CAPITULO 1.

- [1] Crespo Márquez A. (2007). The maintenance management framework. Models and methods for complex systems maintenance. London: Springer Verlag. <https://books.google.cl>
- [2] Turconi, G., Ventola, G., González-Prida, V., Parra, C., Crespo, A. (2022). A Literature Review on Lean Manufacturing in the Industry 4.0: From Integrated Systems to IoT and Smart Factories. In: Verma, J.K., Saxena, D., González-Prida, V. (eds) IoT and Cloud Computing for Societal Good. EAI/Springer Innovations in Communication and Computing. <https://easychair.org>
- [3] Ana González Muñiz. (2018). Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (Deep learning) al análisis y mejora de eficiencia de procesos industriales. <https://www.researchgate.net>
- [4]Javier Mora Pineda. (2022). Predictive models in health based on machine Learning. <https://doi.org/10.1016/j.rmclc.2022.11.002>
- [5] David Kauchak. (2016). Neural Networks. <https://doi.org/10.1016/j.neunet.2024.106392>
- [6] Claudio Aracena, Fabián Villena, Felipe Arias, Jocelyn Dunstan. (2022). Applications of machine Learning in healthcare. <https://doi.org/10.1016/j.rmclc.2022.10.001>
- [7] Sierra-García, J. E, Santos, M. (2021). Neural networks and reinforcement learning in wind turbine control. <https://scispace.com>
- [8] Hugo Chanampe, Silvana Aciar, Martin de la Vega, José Luis Molinari Sotomayor, German Carrascosa, Alejandro Lorefice. (2019). Modelo de Redes Neuronales Convolucionales Profundas para la Clasificación de Lesiones en Ecografías Mamarias. <http://sedici.unlp.edu.ar/handle/10915/77381>
- [9] Ke Chang, Xinna Yu, Wei Ren, Xianmin Jin, Yafei Zhang, Hui Wang. (2024). Artificial vision system based on porosity heterojunction for in-sensor processing and dynamic trace extraction. <https://doi.org/10.1016/j.device.2024.100598>
- [10] José A. Ruz Hernández, Edgar N. Sánchez, Dionisio A. Suárez. (2008). Algoritmo de entrenamiento óptimo para diseñar una memoria asociativa de Diagnóstico de fallas. [https://doi.org/10.1016/S1697-7912\(08\)70129-8](https://doi.org/10.1016/S1697-7912(08)70129-8)

[11] Guangqi CHEN. (2024). Prospects, Challenges and Guidelines for Practical Deep Learning in Geoengineering. <https://doi.org/10.1016/j.ige.2024.10.001>

[12] Álvaro Artola Moreno. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python. <https://idus.us.es>

[13] Manlio Massiris, Claudio Delrieux, J. Álvaro Fernández. (2018). Detección de equipos de protección personal mediante red neuronal convolucional yolo. <http://dx.doi.org/10.17979/spudc.9788497497565.1022>

[14] Iván García, y Víctor Caranqui. (2015). Artificial vision and fields of application. <http://dx.doi.org/10.32645/26028131.76>

[15] M. C. José Jaime Esqueda Elizondo. (2002). Fundamentos de Procesamiento de Imágenes. <https://www.researchgate.net>

[16] <https://www.eleconomista.es> [Accedido en Diciembre 2024].

[17] <https://www.autonocion.com> [Accedido en Diciembre 2024].

[18] <https://www.ancosev.org> [Accedido en Diciembre 2024].

[19] <https://www.bcn.cl> [Accedido en Diciembre 2024].

[20] <https://www.prt.cl> [Accedido en Diciembre 2024].

[22] <https://keepcoding.io> [Accedido en Diciembre 2024].

[23] Valeria Beatriz Angulo De La Fuente. (2024). Detección Temprana De Fallas En Cintas Transportadoras Mediante Visión Computacional Y Deep Learning. <https://repositorio.uchile.cl>

[24] Xi Zhong, Jianquan She, Xiaojie Wu. (2024). Tech for social good: Artificial intelligence and workplace safety. <https://doi.org/10.1016/j.techsoc.2024.102745>

[25] Ismael Castillo-Ortiz, Carmen Villar-Patino, Elizabeth Guevara Martínez. (2024). Computer vision solution for uniform adherence in gastronomy schools: An artificial intelligence casa study. <https://doi.org/10.1016/j.ijgfs.2024.100997>

[26] Pieranto Facco, Andrea C. Santomaso, Massimiliano Barolo. (2017). Artificial vision system for particle size characterization from bulk materials. <https://doi.org/10.1016/j.ces.2017.01.053>

- [27] Jannis Walk, Niklas K hlb, Michael Saidani, J rgen Schatte. (2023). Artificial intelligence for sustainability: Facilitating sustainable smart product-service systems with computer vision. <https://doi.org/10.1016/j.jclepro.2023.136748>
- [28] Karthikeyan S, Subbarayan M R, Mathan Kumar P, Radha Krishnan Beemarajd, Sivakandhan C. (2022). Computer vision-based surface roughness measurement using artificial neural network. <https://doi.org/10.1016/j.matpr.2021.09.314>
- [29] Laura Cano Salinas, Rodrigo Rodr guez Laguna, Jos  Ren  Valdez Lazalde, Otilio Arturo Acevedo Sandoval y Rosa Icela Beltr n Hern ndez. (2016). Monitoring of urban growth in the state of Hidalgo using Landsat images. <https://doi.org/10.14350/rig.52339>
- [30] Yurii Kardovskyi, Sungwoo Moon. (2021). Artificial intelligence quality inspection of steel bars installation by integrating mask R-CNN and stereo vision. <https://doi.org/10.1016/j.autcon.2021.103850>

CAPITULO 2.

- [1] Carlos Alberto Parra M rquez., Crespo M rquez A. (2015). Ingenier a de Mantenimiento y fiabilidad aplicada a la gesti n de activos. <http://dx.doi.org/10.13140/RG.2.2.29363.66083>
- [2] Carlos Parra., Pablo Duque., F lix Pizarro., Andr s Ar nguiz., Vicente Gonz lez Prida., Jorge Parra. (2024). Modelo de gesti n de mantenimiento (MGM) optimizado a partir del uso de tecnolog as de la industria 4.0. <http://dx.doi.org/10.13140/RG.2.2.10581.03044>
- [3] <https://evtech.cl/industria-y-mantenimiento-4-0/> [Accedido en Abril 2025].
- [4] Guillermo Beltr n Cardoso., Jorge Parra Michel., Leobardo Ceja Bravo., Sandra Olivares Bautista., Rafael Mart nez Pel ez. (2021).  Qu  es industria 4?0?: elementos clave de la industria 4.0 <https://www.researchgate.net>
- [5] <https://traction.com> [Accedido en Abril 2025].
- [6] <https://www.edsrobotics.com> [Accedido en Abril 2025].
- [7] Vanessa Alvear., Henry Farinango., Iv n Navarrete., Paul Rosero Montalvo., Jorge Noguera., Fabi n Cuzme., Diego Peluffo. (2016). Internet de las Cosas y Visi n Artificial, Funcionamiento y Aplicaciones: Revisi n de Literatura. <http://dx.doi.org/10.29019/enfoqueute.v8n1.121>
- [8] <https://whitestack.com> [Accedido en Abril 2025].
- [9] <https://industrial.ai> [Accedido en Abril 2025].

-
- [10] Fujitsu. (2019). El Mantenimiento Predictivo en la Industria 4.0. <https://www.clubexcelencia.org>
- [11] <https://www.incentro.com> [Accedido en Abril 2025].
- [12] <https://www.ionos.com> [Accedido en Abril 2025].
- [13] V. M. Arévalo., J. González., G. Ambrosio. (2002). La librería de visión artificial OpenCV aplicación a la docencia e investigación. <https://www.researchgate.net>
- [14] <https://datascientest.com> [Accedido en Abril 2025].
- [15] <https://aprendeconalf.es> [Accedido en Abril 2025].
- [16] <https://www.master-data-scientist.com> [Accedido en Abril 2025].
- [17] <https://www.tensorflow.org> [Accedido en Abril 2025].
- [20] <https://www.sciencedirect.com> [Accedido en Abril 2025].
- [21] <https://docs.ultralytics.com> [Accedido en Abril 2025].
- [22] <https://mcr.es> [Accedido en Mayo 2025].
- [23] <https://ibernova.com> [Accedido en Mayo 2025].