






Determinación de características físicas de elementos mecánicos mediante machine learning

Determination of physical characteristics of mechanical elements using machine learning

- ¹ Rodrigo Rigoberto Moreno Pallares  <https://orcid.org/0000-0003-1877-6942>
Facultad de Mecánica Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador,
rodrigo.moreno@esPOCH.edu.ec
- ² Edwin Fernando Mejía Peñafiel  <https://orcid.org/0000-0001-6888-4621>
Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador, Ecuador.
efmejia@esPOCH.edu.ec
- ³ Edgar Fabian Sánchez Carrión  <https://orcid.org/0000-0002-8027-2799>
Facultad de Mecánica Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador,
Ecuador.
edgar.sanchez@esPOCH.edu.ec
- ⁴ Diego Alejandro Cáceres Veintimilla  <https://orcid.org/0000-0003-0498-1240>
Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador, Ecuador.
diego.caceres@esPOCH.edu.ec



Artículo de Investigación Científica y Tecnológica

Enviado: 08/05/2024

Revisado: 05/06/2024

Aceptado: 10/07/2024

Publicado: 09/08/2024

DOI: <https://doi.org/10.33262/concienciadigital.v7i3.1.3115>

Cítese:

Moreno Pallares, R. R., Mejía Peñafiel, E. F., Sánchez Carrión, E. F., & Cáceres Veintimilla, D. A. (2024). Determinación de características físicas de elementos mecánicos mediante machine learning. *ConcienciaDigital*, 7(3.1), 6-17. <https://doi.org/10.33262/concienciadigital.v7i3.1.3115>



CONCIENCIA DIGITAL, es una revista multidisciplinar, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec



Esta revista está protegida bajo una licencia Creative Commons AttributionNonCommercialNoDerivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

Palabras claves:

Control, calidad, ingeniería, red neuronal, clasificación, imágenes

Keywords:

Control, quality, engineering, neural network, classification, images

Resumen

Introducción. Uno de los problemas cotidianos de las personas es verificar el estado de diversas autopartes que se distribuyen en grandes cantidades, debido a que de ello dependen varios almacenes de repuestos que distribuyen piezas mecánicas para satisfacer a los clientes y su entorno en general. Para cubrir tales necesidades se han desarrollado redes neuronales artificiales que clasificarán estos elementos según sus características físicas. La adquisición de piezas mecánicas en la industria del automóvil se repite en innumerables ocasiones, por lo que pueden comprar piezas mecánicas defectuosas. **Objetivo.** Clasificación de elementos mecánicos mediante redes neuronales artificiales para su uso en control de calidad en sus características físicas. **Metodología.** Se aplica una metodología de recopilación de datos que ayudarán a entrenar a la red neuronal artificial. La red neuronal artificial podrá determinar el estado de calidad del elemento mecánico basándose en los datos de imágenes recopiladas y actuará como entrenamiento de la red neuronal en el siguiente proceso. **Resultados.** En la prueba final se utilizaron 200 uniones metálicas de estas clasificadas y se observó que 10 tenían defectos físicos. **Conclusión.** Las redes neuronales convolucionales se pueden utilizar para clasificar piezas mecánicas, extraer sus características de imágenes y luego utilizarlas como base de datos de redes neuronales. **Área de estudio general:** Ingeniería. **Área de estudio específica:** Ingeniería automotriz. **Tipo de estudio:** original.

Abstract

Introduction. One of people's daily problems is verifying the status of various auto parts that are distributed in large quantities, because several spare parts warehouses that distribute mechanical parts depend on it to satisfy customers and their environment in general. To cover such needs, artificial neural networks have been developed that will classify these elements according to their physical characteristics. The acquisition of mechanical parts in the automobile industry is repeated countless times, so they can purchase defective mechanical parts. **Objective.** Classification of mechanical elements using artificial neural networks for use in quality control of their physical characteristics. **Methodology.** A data collection

methodology is applied that will help train the artificial neural network. The artificial neural network will be able to determine the quality status of the mechanical element based on the collected image data and will act as training of the neural network in the following process. **Results.** In the final test, 200 of these classified metal joints were used and it was observed that 10 had physical defects. **Conclusion.** Convolutional neural networks can be used to classify mechanical parts, extract their features from images, and then use them as a neural network database.

Introducción

Hoy en día, hablar de redes neuronales artificiales puede resultar muy complicado tal como las entendemos, pero su aplicación a diversos problemas cotidianos ha resuelto innumerables de los mismos problemas y ha ayudado a las personas a mejorar sus tareas cotidianas (Olabe, 2016). En la industria automotriz la inspección que se realice a cada una de sus partes obedece no sólo a criterios de diseño, sino a un factor de seguridad (Gamarra & Bertel, 2014).

Uno de los problemas cotidianos de las personas es verificar el estado de diversas autopartes que se distribuyen en grandes cantidades, debido a que de ello dependen varios almacenes de repuestos que distribuyen piezas mecánicas para satisfacer a los clientes y su entorno en general (Poblet, 2022). Para cubrir tales necesidades se han desarrollado redes neuronales artificiales que clasificarán estos elementos según sus propiedades y determinarán su estado (Mateo-Jiménez et al., 2021).

Se han desarrollado Redes Neuronales Convolucionales (CNR) (Aljure, 20215), con Análisis de Componentes Principales (PCA) y Redes Neuronales Convolucionales sin PCA (Artola 2019), para clasificar piezas metálicas en función de su geometría (regular o irregular). En los experimentos, se logró una precisión de al menos el 93 % utilizando un diseño factorial con variables que incluyen: iluminación, número de neuronas de capa oculta, tipo de optimización y número de componentes (Aguilar-Alvarado & Campoverde-Molina, 2019). Las partes metálicas están expuestas a luz fría y cálida en tres niveles de luz: 1000 lux, 1500 lux y 2000 lux, con base en la norma oficial mexicana NOM-025-STPS-2008. La imagen se procesa previamente mediante análisis de componentes principales para eliminar el ruido de los datos redundantes (generalmente debido a la dimensionalidad) y producir una dimensión más pequeña que la dimensión

original, lo que permite que la red neuronal convolucional reciba una pequeña cantidad de material de entrada (Mateo-Jiménez et al., 2021).

Metodología

Este trabajo de investigación se basa en un enfoque cuantitativo utilizando la recolección y análisis de datos utilizando herramientas estadísticas para sustentar las hipótesis de investigación propuestas (Arispe et al., 2020, p. 57).

En este caso utilizamos el método deductivo, con base en el marco teórico y la información obtenida sacaremos conclusiones que cumplan con los objetivos del estudio para encontrar soluciones a los problemas de investigación. Este método implica recopilar datos que ayudarán a entrenar la propia red neuronal artificial. La red neuronal artificial podrá determinar el estado de calidad de la junta metálica basándose en la base de datos de imágenes recopiladas y actuará como entrenamiento de la red neuronal en el siguiente proceso: A través de la capa ANN oculta, los datos obtenidos se utilizarán para determinar la calidad de una determinada cantidad de piezas metálicas compradas a un distribuidor de autopartes (Lubinus et al., 2021).

La investigación ofrece un nivel descriptivo, que tiene como objetivo esclarecer las características del objeto de análisis, es decir, solo mide y recolecta información independientemente de las variables estudiadas e indica los motivos para recolectar estos datos.

Se encuentran rangos de correlación para relacionar variables usando patrones predecibles, cada variable se mide inicialmente, luego se cuantifica, se analiza y luego se relaciona (Cadena & Heredia, 2018). Esto permite la recopilación en tiempo real de datos físicos sobre conjuntos metálicos obtenidos por los distribuidores de autopartes y vincular esta información a una base de datos de imágenes en la capa oculta de la ANN (Chirinos & Calero, 2021).

Un comunicado ubicado en el Boletín Estadístico y Autopartes emitido por la Cámara de la Industria Automotriz del Ecuador (CINAE) muestra que entre marzo de 2022 y marzo de 2023 se registró un aumento significativo en el volumen de importaciones de autopartes en dólares estadounidenses. En marzo de 2022, el volumen total de importación de autopartes en dólares estadounidenses fue de 121050328,06 (Gila, 2022).

La Asociación de Empresas Automotrices del Ecuador (AEADE, 2022), concluyó que la mayoría de los ecuatorianos prefieren almacenes que distribuyan universales o repuestos, mientras que una minoría se inclina claramente por comprar. Sin repuestos exclusivos, u originales. Actualmente, aproximadamente el 75% de los repuestos son genéricos y el 25% originales. Teniendo esto en cuenta, se realizó una encuesta en un almacén de General Motors o concesionario de repuestos que cumple con los requisitos necesarios

para autopartes que se pueden comprar en grandes cantidades y distribuir muy rápidamente, con base en esta información se realizó la encuesta en General Motors se ubica en Latacunga almacén de repuestos “Motor Solutions”


Resultados

Para este grupo se definieron 1.000 imágenes que contenían los defectos más comunes en los conjuntos metálicos derivados del almacenamiento, transporte, fabricación, etc. (Basulto, 2018). Además, se identificaron 1.000 imágenes de conjuntos metálicos en buen estado, dado que algunos de estos defectos eran extremadamente pequeños. y se puede distribuir sin problemas.

Las pruebas y resultados obtenidos durante la validación de una Red Neuronal Convolutiva (CNN) utilizando el código presentado en el capítulo anterior. Entre ellos, Yvalidation es la variable de entrada, YPred es la salida, que se convierte en el resultado final de CNN, y luego calcula las puntuaciones de "PRECISIÓN y EXACTITUD" para cada red neuronal (Narciso & Manzano, 2021). La figura 1 muestra la matriz de confusión de una red neuronal convolutiva.

Figura 1

Matriz de confusión CNN N°1



La atención se centra en los resultados de ambos programas. El resultado "defectuoso" es que 345 imágenes están clasificadas correctamente, lo que corresponde a una precisión "defectuosa" del 77,4%. Hay 48 imágenes con una precisión del 10,9%. CNN #1 en este

estudio clasificó con éxito 393 imágenes de 446 imágenes de prueba, las cuales, expresadas como porcentaje, clasificaron correctamente el 88,1% y el 11,9% de falsos negativos, falsos positivos y falsos positivos, respectivamente. Un verdadero caso de evaluación negativa.

Tabla 1

Variables de la matriz de confusión modelo N°1

Valor	TP	FP	TN	FN
Defectuosos	345	0	48	53
Sin defecto	48	53	345	0

Valor “defectuosa”

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

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

Valor “sin defecto”

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

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

Evaluación de matriz de confusión CNN N°2

El resultado "defectuoso" es que 397 imágenes están clasificadas correctamente, lo que corresponde a una precisión del 89,0%. Para este modelo, de un total de 446 imágenes de validación, 443 imágenes se clasificaron correctamente como porcentaje, con una tasa de clasificación correcta del 99,3% para falsos negativos, 0,7% para falsos positivos y 0,7% para verdaderos negativos. cada caso de evaluación.

Tabla 2

Variables de la matriz de confusión modelo N°2

Valor	TP	FP	TN	FN
Defectuosos	397	2	46	1
Sin defecto	46	1	397	2

Valor “defectuosa”

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

$$Precision = \frac{397}{397+2} = 0.99$$

Valor “sin defecto”

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

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

Tabla 3

Comparación de valores de la tablade confusión

CNN	Valor	TP	FP	TN	FN
N. 1	Defectuosos	345	0	48	53
	Sin defecto	48	53	345	0
N. 2	Defectuosos	397	2	46	1
	Sin defecto	46	1	397	2

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

Tabla 4

Comparación métrica de precisión

CNN	Valor	Precisión	Promedio total %
N. 1	Defectuosos	1	73,5
	Sin defecto	0,47	
N. 2	Defectuosos	0,99	98,5
	Sin defecto	0,98	

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

Tabla 5


Comparación métrica “accuracy”

CNN	Valor	Precisión	Promedio total %
N. 1	Defectuosos	0,88	88
	Sin defecto	0,88	
N. 2	Defectuosos	0,99	99
	Sin defecto	0,99	

La prueba final utilizó un lote de 200 juntas metálicas compradas recientemente en una tienda de repuestos de Motor Solutions. Sin embargo, sugirieron un pequeño error en el entrenamiento de CNN debido a la tolerancia de error almacenada; las uniones clasificadas con esta tolerancia se pueden usar sin problemas. La figura 2 muestra enlaces tolerantes a fallas.

Figura 2

Tolerancia de clasificación



Discusión

Se han desarrollado Redes Neuronales Convolucionales (CNR) con Análisis de Componentes Principales (PCA) y Redes Neuronales Convolucionales sin PCA para clasificar piezas metálicas en función de su geometría (regular o irregular). En los experimentos, se logró una precisión de al menos el 93 % utilizando un diseño factorial con variables que incluyen: iluminación, número de neuronas de capa oculta, tipo de optimización y número de componentes. Las partes metálicas están expuestas a luz fría y cálida en tres niveles de luz: 1000 lux, 1500 lux y 2000 lux, con base en la norma oficial mexicana NOM-025-STPS-2008. La imagen se preprocesa mediante análisis de componentes principales para eliminar el ruido de los datos redundantes (generalmente

debido a la dimensionalidad) y obtener una dimensión más pequeña que la dimensión original, lo que permite que la red neuronal convolucional reciba una pequeña cantidad de información de entrada (Mateo-Jiménez et al., 2021).

Conclusiones

- Las RNA convolucionales pueden ser aplicadas en la clasificación de piezas mecánicas, extrayendo sus características a través de imágenes que posteriormente servirán de base de datos para la RNA.
- De la gran variedad de repuestos se seleccionó juntas metálicas ya que presentan mayor demanda en ventas, por medio de datos históricos se determinó que, al adquirir 200 juntas metálicas mensuales en el año 2022, un total de 43 de ellas resultó defectuosas.
- Se utilizó 1000 imágenes para cada grupo de estudio y fueron utilizadas para el entrenamiento de la RNA con el fin de que su aplicación sea exitosa.

Conflicto de intereses

Los autores expresan que no hay conflictos de interés en el manuscrito presentado.

Referencias Bibliográficas

- Aguilar-Alvarado, J. V., & Campoverde-Molina, M. A. (2019). Clasificación de frutas basadas en redes neuronales convolucionales. *Polo del Conocimiento*, 5(1), 3-22. <https://dialnet.unirioja.es/servlet/articulo?codigo=7436055>
- Aljure, Y. (2021). *Clasificación de flores con redes neuronales convolucionales* [Tesis de posgrado, Universidad de Antioquia. Colombia, Medellín, Colombia]. https://bibliotecadigital.udea.edu.co/bitstream/10495/24683/1/AljureYalila_2021_ClasificacionImagenesFlores.pdf
- Arispe, C., Yangali, J., Guerrero, M., Lozada, O., Acuña, L., & Arellano, C. (2020). *La investigación científica*. Editorial Universidad Internacional del Ecuador. <https://repositorio.uide.edu.ec/bitstream/37000/4310/1/LA%20INVESTIGACION%20CIENTIFICA.pdf>
- Artola Moreno, Álvaro. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python* [Tesis de pregrado, Universidad de Sevilla, España]. <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1&isAllowed=y>
- Asociación de Empresas Automotrices del Ecuador [AEADE]. (2022). *Anuarios*. <https://www.aeade.net/anuario/>

- Basulto Rodríguez, Y. (2018). *Integración de la red neuronal convolucional con el algoritmo de función de frontera de objeto para reconocimiento de piezas y detección de defectos* [Tesis de maestría, Corporación Mexicana de Investigación en Materiales, México]
<https://comimsa.repositorioinstitucional.mx/jspui/bitstream/1022/322/1/Tesis%20de%20Maestr%C3%ADa%20Yanier%20Basulto%20Rodr%C3%ADguez.pdf>
- Cadena, L & Heredia, J. (2018). *Sistema inteligente con visión artificial para el reconocimiento de piezas mecánicas en el robot NAO* [Tesis de pregrado, Universidad Politécnica Salesiana. Ecuador].
<http://dspace.ups.edu.ec/handle/123456789/15012>
- Chirinos Carranza, X., & Calero Segura, P. (2021). *Detección del uso correcto de mascarillas utilizando una red neuronal convolucional para el ingreso de personas a un laboratorio de una universidad* [Tesis de pregrado, Universidad Ricardo Palma, Lima, Perú].
<https://hdl.handle.net/20.500.14138/4918>
- Gamarra, M., & Bertel, F. (2014). Clasificación de piezas metalmecánicas basado en algoritmos inteligentes implementando procesamiento digital de imágenes [12th Latin American and Caribbean Conference for Engineering and Technology].
https://www.academia.edu/68527796/Clasificaci%C3%B3n_De_Piezas_Metalmec%C3%A1nicas_Basado_En_Algoritmos_Inteligentes_Implementando_Procesamiento_Digital_De_Im%C3%A1genes
- Gila Hoya, A. (2022). *El mercado de repuestos y autopartes en Ecuador*. Editado por ICEX España Exportación e Inversiones
<https://www.icex.es/content/dam/es/icex/oficinas/096/documentos/2022/10/documentos-anexos/DOC2022915769.pdf>
- Lubinus Badillo, F., Rueda Hernández, C. A., Marconi Narváez, B., & Arias Trillos, Y. E. (2021). Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema. *Revista Colombiana de Radiología*, 32(3), 5591–5599. <https://doi.org/10.53903/01212095.161>
- Mateo-Jiménez, M., Granda-Gutiérrez, E. E., Rangel-Velázquez G. I., Torres-Reyes, C. E., & Pérez-Martínez, J. A. (2021). Implementación de técnicas de visión artificial en un sistema de reconocimiento facial para alertar el robo de automóviles. *Journal Aristas: Investigación básica y aplicada*, 8(16), 219-225.
http://revistaaristas.tij.uabc.mx/index.php/revista_aristas/article/view/107

Narciso Horna, W. A., & Manzano Ramos, E. A. (2021). Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos según estándares de exportación. *Campus*, 32, 155–166.

<https://www.usmp.edu.pe/campus/pdf/revista32/articulo1.pdf>

Olabe, X. B. (2016). *Redes neuronales artificiales y sus aplicaciones* [Curso: Redes Neuronales Artificiales y sus Aplicaciones]. Escuela Superior de Ingeniería de Bilbao, EHU, 2016.

https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf

Poblet García, P. (2022). *Detección de defectos en latas de refrescos mediante redes neuronales y visión artificial* [Tesis de pregrado, Escuela Técnica Superior de Ingeniería industrial de Barcelona, España].

<https://upcommons.upc.edu/handle/2117/371689>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



Indexaciones

