

Arquitectura para clasificación y caracterización de materiales para minimizar impacto por su alta variación

Everardo Gómez Sánchez^{1*}, David Luviano Cruz², Ángel Israel Soto Marrufo³

Resumen

En los últimos años, la investigación y el desarrollo de proyectos centrados en áreas de la inteligencia artificial (IA) con aplicaciones de aprendizaje automático, aprendizaje profundo, redes neuronales y autoaprendizaje han experimentado un crecimiento exponencial, siendo una de sus aplicaciones más relevantes el procesamiento de imágenes. La información existente sobre este tema está dispersa, a pesar de que el procesamiento de imágenes permite clasificar y definir las propiedades de los sistemas de interés, y a partir de esta información se pueden realizar funciones variadas. Por este motivo, en este trabajo se lleva a cabo una revisión bibliográfica centrada en la síntesis de la información científica relacionada con el procesamiento de imágenes mediante redes neuronales en el sector automotriz. En el caso de las aplicaciones para controles de calidad, si el procesamiento se realiza de forma eficiente, es posible reducir el alto índice de falsos rechazos, disminuir el riesgo de error en las inspecciones manuales, evitar la pérdida de material por pruebas destructivas convencionales y disponer de un sistema de autoaprendizaje predictivo que permita minimizar de forma autónoma, eficiente y económica el impacto de la alta variación en los materiales y procesos.

Palabras Clave

Inteligencia artificial – Redes neuronales – Procesamiento de imagen – Área automotriz

^{1,2,3}Departamento de Ingeniería Industrial y Manufactura, Universidad Autónoma de Ciudad Juárez, México.

***Autor de correspondencia:** al263345@alumnos.uacj.mx

Programa académico

Doctorado en Tecnología

Fecha de presentación

20 y 27 de noviembre de 2025

Financiamiento

Sin financiamiento

Institución responsable del estudio

Universidad Autónoma de Ciudad Juárez

Eventos académicos

10.º Coloquio de Posgrados del IIT, 1.º Congreso Internacional de las Fronteras de las Ingenierías

Conflicto de interés

Sin conflicto de interés declarado

Referencias

1. Iqbal, M. A., Wang, Z., Ali, Z. A., & Riaz, S. (2021). Automatic fish species classification using deep convolutional neural networks. *Wireless Personal Communications*, 116, 1043-1053.
2. Kozamernik, N., & Bračun, D. (2025). A novel FuseDecode Autoencoder for industrial visual inspection: Incremental anomaly detection improvement with gradual transition from unsupervised to mixed-supervision learning with reduced human effort. *Computers in Industry*, 164, 104198.
3. Li, X., Lin, W., & Guan, B. (2023). The impact of computing and machine learning on complex problem-solving. *Engineering reports*, 5(6), NA-NA.
4. Mjimer, I., Aoula, E. S., & Achouyab, E. H. (2023). Contribution of machine learning in continuous improvement processes. *Journal of Quality in Maintenance Engineering*, 29(2), 553-567.
5. Rahman Fahim, S., K. Sarker, S., Mueyen, S. M., Sheikh, M. R. I., & Das, S. K. (2020). Microgrid fault detection and classification: Machine learning based approach, comparison, and reviews. *Energies*, 13(13), 3460.

CITACIÓN: Gómez Sánchez, E., Luviano Cruz, D., & Soto Marrufo, A.I. (2026). Arquitectura para clasificación y caracterización de materiales para minimizar impacto por su alta variación [Fronteras de la Ingeniería y Transformación Tecnológica]. *Memorias Científicas y Tecnológicas*, 5(1), 99-100.



ARQUITECTURA PARA CLASIFICACIÓN Y CARACTERIZACIÓN DE MATERIALES PARA MINIMIZAR IMPACTO POR SU ALTA VARIACIÓN

M.I.I. Everardo Gómez Sánchez

Dr. David Luviano Cruz

Dr. Angel Israel Soto

Resumen

Se propone desarrollar una arquitectura para clasificación y caracterización de materiales para minimizar el impacto de la alta variación en carcasas y sub ensamblés del área industrial automotriz. Mediante procesamiento de imagen por medio de redes neuronales convolucionales será posible la generación de un *dataset*, entrenamiento, obtención de características distintivas y caracterización de dichos materiales. Por medio de la arquitectura se espera contar con un nivel de precisión y autoaprendizaje que aporte un avance científico en las áreas de Inteligencia artificial, *machine learning*, redes neuronales y sistemas de visión.




Figura 1. (Gouillart et al., 2016)

Introducción

El Machine Learning (ML) se basa en el entrenamiento y la clasificación de características distintivas. En los últimos años se ha convertido en un área de investigación y desarrollo relevante, ya que contribuye de manera significativa en la resolución de problemas [1] y la mejora continua [2] en proyectos de investigación e implementación de distinta naturaleza. Diversos sistemas utilizan este mecanismo para el reconocimiento, la clasificación y la detección de fallos [3]. Uno de los métodos de aprendizaje automático más utilizados por su alta eficiencia es el método de redes neuronales. Un elemento indispensable en el uso de éstas, es el conjunto de datos de entrenamiento; pero, actualmente no existen conjuntos de datos centrados en materiales específicos, como los dispositivos del sector industrial automotriz [4]. Por lo tanto, con la información preliminar obtenida en la literatura no es posible realizar una clasificación y caracterización eficientes con los modelos y arquitecturas actuales [5].

Metodología Redes neuronales convolucionales





Figura 2. (Cecotti, H., 2011)

Objetivo general

Desarrollar una arquitectura para clasificación y caracterización de materiales para minimizar el impacto de la alta variación en carcasas y sub ensamblés del área industrial automotriz.

Resultados esperados

Como resultados esperados se tiene la generación de una arquitectura para aplicaciones específicas de clasificación y caracterización de materiales de carcasas y sub ensamblés en el área industrial automotriz. También se espera contar con un nivel de auto aprendizaje aceptable que permita disminuir el impacto por la alta variación en dichos materiales con características definidas y específicas, por lo cual la implementación en otro tipo de materiales puede tener valores de funcionalidad, eficiencia y salida distintos.

Objetivos particulares

- Clasificar carcasas y sub ensamblés
- Generación de *dataset* de entrenamiento
- Validar la detección precisa
- Validar el nivel de auto aprendizaje

Referencias

- [1] Li, X., Lin, W., & Guan, B. (2023). "The impact of computing and machine learning on complex problem-solving". Engineering reports, 5(6), NA-NA.
- [2] Mjimer, I., Aoula, E. S., & Achouyab, E. H. (2023). "Contribution of machine learning in continuous improvement processes". Journal of Quality in Maintenance Engineering, 29(2), 553-567.
- [3] Rahman Fahim, S., K. Sarker, S., Mueen, S. M., Sheikh, M. R. I., & Das, S. K. (2020). "Microgrid fault detection and classification: Machine learning based approach, comparison, and reviews". Energies, 13(13), 3460.
- [4] Kozamernik, N., & Bračun, D. (2025). "A novel FuseDecode Autoencoder for industrial visual inspection: Incremental anomaly detection improvement with gradual transition from unsupervised to mixed-supervision learning with reduced human effort". Computers in Industry, 164, 104198.
- [5] Iqbal, M. A., Wang, Z., Ali, Z. A., & Riaz, S. (2021). "Automatic fish species classification using deep convolutional neural networks". Wireless Personal Communications, 116, 1043-1053.

Conclusiones

Como conclusiones esperadas se tiene definido que la arquitectura propuesta minimizará el impacto de la alta variación de materiales de carcasas y sub ensamblés en el área industrial automotriz con un nivel de auto aprendizaje aceptable.

Como verificación esperada se tiene una comparación precisa y eficiente de los resultados obtenidos a comparación de los resultados que se obtienen actualmente por medio de inspección manual y procesos de control basados en criterios de calidad ya definidos.