



Artículo de Investigación

Agilización del control de calidad en la industria metalúrgica mediante redes neuronales artificiales

Streamlining quality control in the metallurgical industry using artificial neural networks

RESUMEN

En la industria metalúrgica, los ensayos de control de calidad suelen basarse en pruebas destructivas que consumen tiempo y material, lo que motiva la búsqueda de alternativas computacionales más eficientes. En este trabajo se presentan ejemplos prácticos del uso de aprendizaje automático (machine learning) y aprendizaje profundo (deep learning) para agilizar procesos de control de calidad en aleaciones metálicas. Se desarrollan modelos de regresión para la predicción de dos propiedades mecánicas y modelos de clasificación para la identificación de tres tipos de aleaciones, empleando datos tabulares e imágenes. Para la regresión se evaluaron diversos algoritmos, destacándose el perceptrón multicapa por su alto desempeño predictivo. En la clasificación se utilizó una red convolucional basada en MobileNetV2, logrando métricas competitivas a pesar del desbalance de clases presente en los datos. Los resultados demuestran que las redes neuronales pueden reducir significativamente los tiempos de análisis y apoyar la toma de decisiones en entornos industriales, contribuyendo a procesos de control de calidad más rápidos y eficientes.

Autor de Correspondencia

Robert Yesid Barrios Acendra
rbarriosa@unicartagena.edu.co
Universidad de Cartagena

Artículo Recibido: 14 de mayo, 2026
Artículo Aceptado: 12 de junio, 2026
Artículo Publicado: 30 de septiembre, 2026



Palabras clave: Aprendizaje automático; Aprendizaje profundo; Redes neuronales; Control de calidad; Industria metalúrgica.

ABSTRACT

In the metallurgical industry, quality control testing is often based on time-consuming and material-intensive destructive tests, motivating the search for more efficient computational alternatives. This paper presents practical examples of the use of machine learning and deep learning to streamline quality control processes in metal alloys. Regression models are developed for predicting two mechanical properties, and classification models are developed for identifying three types of alloys, using tabular data and images. Various algorithms were evaluated for regression, with the multilayer perceptron standing out for its high predictive performance. A convolutional neural network based on MobileNetV2 was used for classification, achieving competitive metrics despite the class imbalance present in the data. The results demonstrate that neural networks can significantly reduce analysis times and support decision-making in industrial environments, contributing to faster and more efficient quality control processes.

Keywords: Machine learning; Deep learning; Neural networks; Quality control; Metallurgical industry.

Introducción

La industria metalúrgica y siderúrgica en sus pruebas de control de calidad como tensil, tracción, impacto, dureza, compresión, usa muestras que son destruidas en los ensayos de control, que también toma tiempo reunir los resultados de cada una, por lo que urge de soluciones para rápidos resultados de control de calidad, impulsando la productividad y reduciendo costos asociados al desperdicio de material (Palatto *et al.*, 2020; Safdar *et al.*, 2025). En el campo de la inteligencia artificial, hay subcampos como el aprendizaje automático (ML) y el aprendizaje profundo (DL), que básicamente buscan aprender patrones a partir de datos para realizar tareas que tradicionalmente requerían intervención humana, y pueden ayudar en agilizar esos controles de calidad (Kotsiopoulos *et al.*, 2021). Los algoritmos de estos dos subcampos pueden entrenarse con unos parámetros de entrada y uno o más parámetros de salida, teniendo aplicaciones en muchos campos del saber como la salud, economía, industrias químicas, metalúrgicas, siderúrgica, etc (Kotsiopoulos *et al.*, 2021).

Los tipos de tareas más conocidas para modelado en ML y DL son de regresión y clasificación. La regresión es cuando se busca predecir una variable continua, como el módulo de Young, por ejemplo. La clasificación busca predecir una variable categórica, como a partir de una imagen definir qué hay en la imagen, si un perro, un gato (Rumelhart *et al.*, 1986; Wythoff, 1993).

En metalurgia, se ven trabajos de regresión para predicción de distintas propiedades mecánicas útiles al contexto del negocio donde se hayan proveído los datos. En estos modelos se usan algoritmos de los dos subcampos mencionados (Adarsh y Sampath, 2020; Arunadevi *et al.*, 2023; Bhandari *et al.*, 2020). También se aprecian trabajos de clasificación de tipos de aleaciones, ya sean ésta con datos de imágenes de microscopía de las aleaciones o bien sea con datos tabulares de la composición del metal (Belayadi y Bourahla, 2019; Warmuzek *et al.*, 2021; Gao *et al.*, 2025; Tariq *et al.*, 2025; Tran *et al.*, 2025).

El entrenamiento de redes neuronales consta de un algoritmo cuyo objetivo general consta de en cada ciclo iterar los pesos de la red para minimizar una función de error, también conocida como función de

costo, o en inglés, loss function, se establece de esta manera general: ya establecida la estructura de la red, iniciar los pesos y sesgos de la red a números aleatorios, se entra a un ciclo de un número determinado de épocas, en cada época, se calcula la función de costo y se imprime, se calcula la matriz o matrices de derivadas con el algoritmo de retropropagación (o su nombre en inglés, backpropagation), esta matriz o matrices tendrán las mismas dimensiones que las de cada capa de la red, con la o las matrices calculadas se actualizan los pesos y sesgos con el llamado descenso del gradiente (Wythoff, 1993) y usando un factor llamado la tasa de aprendizaje. Este proceso se repite hasta alcanzar la convergencia o que se terminen las épocas. Cada época, el algoritmo de retropropagación usa la derivada como herramienta para indicar la dirección en donde se encuentra el mínimo global de la función de costo. Esa búsqueda de acercarse al mínimo se logra paso a paso con el descenso del gradiente (Rumelhart *et al.*, 1986; Wythoff, 1993).

El objetivo de este artículo es mostrar ejemplos prácticos de regresión y clasificación, tomando unos datos de aleaciones y hacer de ellos un modelado para regresión de 2 propiedades mecánicas, también hacer clasificación de 3 tipos de aleaciones, mostrando el poder que tienen las redes neuronales para acelerar las tareas repetitivas, demoradas, que puedan hacerse en menos tiempo e impulsar la reducción de tiempos de análisis.

Materiales y Métodos

Datos y software

La data es sobre aleaciones de metales, temperaturas a las que son expuestos, muchas columnas de los metales que componen cada aleación, sus cantidades y valores de propiedades mecánicas. También posee un conjunto de imágenes de 3 clases principales de aleaciones. Python fue el lenguaje de programación usado, Scikit-learn fue la librería para escalado y modelado para regresión y Tensorflow fue usada para la clasificación. Pandas para lectura de los datos, Matplotlib para graficado de muestra de aleaciones y de resultados de predicciones.

Imágenes de Aleaciones - 3 de cada tipo




Figura N° 1. Muestras de aleaciones. Primera fila: CPJ, segunda fila: HR, tercera fila: P92.

Procesamiento de datos

Para el caso de regresión, la data fue limpiada, esto es, filas con valores nulos, eliminadas columnas completamente nulas.

Ya sea para regresión o clasificación, la data fue separada 80% para entrenamiento, 20% para prueba. En regresión se modelaron 2 propiedades: tensil stress y yield stress. En clasificación se buscaron clasificar entre 3 tipos de aleaciones metálicas de siglas desconocidas: CPJ, HR y P92. Respectivamente, en el dataset completo se encontraron 430, 311 y 96 imágenes.

Modelos

Se probaron diversos algoritmos de machine learning para regresión como XGBoost (XGB), ElasticNet (EN), Random Forest (RF), Gradient Boosting, Support

Vector Regressor (SVR), Light Gradient Boosting Machine (LGBM) y de deep learning se usó Multilayer Perceptron (MLP), el cual es la misma red neuronal, pero bajo otro nombre. En clasificación, se usó la red MobileNetV2 (Safdar *et al.*, 2025) con unas capas extra de personalización para la distinción de los tipos de aleaciones.

Métricas de evaluación

Para regresión, la red MLP fue evaluada con el error estándar relativo porcentual (%RSE) y el coeficiente de determinación R2. En clasificación se usaron las métricas accuracy y precision.

$$\%RSE = \frac{\sqrt{MSE}}{\bar{Y}} * 100$$

Resultados

En cuanto a la regresión, la Tabla N° 1 y la Figura N° 2 muestran la dispersión de las predicciones en los conjuntos de entrenamiento y prueba. El modelo MLP obtuvo los mejores resultados en ambas propiedades mecánicas, presentando los valores más

bajos de %RSE y altos coeficientes de determinación en entrenamiento. Los modelos mostraron un desempeño competitivo, aunque con mayor error en el conjunto de prueba.

En la clasificación sus resultados se muestran en la Tabla N° 2 y la Figura N° 3 tiene su matriz de confusión.

Propiedad mecánica	Modelo	Train		Test	
		R2 %	RSE	R2	% RSE
Yield stress	MLP	0.99	1.32	0.99	3.83
	Gradient Boosting	0.99	1.55	0.97	5.78
	Random Forest Regressor	1.0	0.00	0.96	6.48
Tensil stress	MLP	0.99	0.70	0.99	3.35
	Gradient Boosting	0.99	0.36	0.98	5.62
	XGBoost Regressor	0.99	0.66	0.97	6.25

Tabla N° 1. Resultados de regresión

Modelo	Accuracy		Precision	
	Train	Test	Train	Test
Custom MobileNetV2	0.91	0.95	0.95	0.94

Tabla N° 2. Resultados de clasificación




Figura N° 2. Predicciones vs valores reales de las propiedades mecánicas




Figura N° 3. Matriz de confusión de tipos de aleaciones.

Discusión

Los resultados de clasificación moderados tanto en entrenamiento como en prueba, así como lo observado en la matriz de confusión, pueden atribuirse principalmente al marcado desbalance de clases presente en el conjunto de datos. Durante el proceso de entrenamiento, el modelo tiende a ajustar sus pesos y sesgos favoreciendo la clase mayoritaria, lo que afecta la capacidad de generalización sobre las clases minoritarias. La incorporación de ponderación de clases permitió mitigar parcialmente este efecto, aunque sin resolverlo por completo.

Existen estrategias más robustas para abordar este tipo de desbalance, como por mencionar la obtención de más datos, en este caso no se pudo dado que son datos obtenidos en internet. A pesar de ello, los resultados obtenidos confirman que el modelo es capaz de extraer patrones relevantes y que el enfoque propuesto es viable para aplicaciones de control de calidad.

Conclusiones

En este trabajo se demostró que los datos empleados en procesos industriales metalúrgicos pueden ser utilizados no solo para análisis descriptivos, sino también para la construcción de modelos predictivos y clasificadores con alto desempeño. Mediante técnicas de aprendizaje automático y aprendizaje profundo, fue posible abordar tareas de regresión para la predicción de propiedades mecánicas y tareas de clasificación para la identificación de distintos tipos de aleaciones metálicas.

Los resultados evidencian que las redes neuronales, en particular el perceptrón multicapa y arquitecturas convolucionales ligeras, constituyen herramientas eficaces para apoyar los procesos de control de calidad, permitiendo reducir tiempos de análisis y complementar los ensayos tradicionales. En conjunto, el enfoque propuesto muestra el potencial de la inteligencia artificial como una alternativa viable para mejorar la eficiencia y la toma de decisiones en la industria metalúrgica.

Referencias

- Adarsh SH, Sampath V. 2020. Prediction of high temperature deformation characteristics of an Fe-based shape memory alloy using constitutive and artificial neural network modelling. *Materials Today Communications* 22. <https://doi.org/10.1016/j.mtcomm.2019.100841>
- Arunadevi M, Rani M, Sibinraj R, Chandru MK, Durga C. 2023. Comparison of k-nearest neighbor and artificial neural network prediction in the mechanical properties of aluminum alloys. *Materials Today Proceedings* <https://doi.org/10.1016/j.matpr.2023.09.111>
- Belayadi A, Bourahla B. 2019. Neural network model for 7000 (Al-Zn) alloys: Classification and prediction of mechanical properties. *Physica B Condensed Matter* 554: 114 - 120. <https://doi.org/10.1016/j.physb.2018.11.012>
- Bhandari U, Rafi MR, Zhang C, Yang S. 2020. Yield strength prediction of high-entropy alloys using machine learning. *Materials Today Communications* 26. <https://doi.org/10.1016/j.mtcomm.2020.101871>
- Gao Z, Zhuang J, He X. 2025. FALCON-Net: A hybrid fuzzy-attentive LSTM-convolutional neural network architecture for high-precision classification of steel alloys via femtosecond laser-ablation spark-induced breakdown spectroscopy. *Analytica Chimica Acta* 1378. <https://doi.org/10.1016/j.aca.2025.344701>
- Kotsiopoulos T, Sarigiannidis P, Ioannidis D, Tzovaras D. 2021. Machine learning and deep learning in smart manufacturing: The smart grid paradigm. *Computer Science Review* 40. <https://doi.org/10.1016/j.cosrev.2020.100341>
- Palatto LF, Gutiérrez L, Vargas E, Vargas BL. 2020. A methodology for the optimization of mechanical properties of automotive iron-casting brakes using artificial neural networks. *Procedia Manufacturing* 52, 162 - 167. <https://doi.org/10.1016/j.promfg.2020.11.029>
- Rumelhart D, Hinton G, Williams R. 1986. Learning representations by back-propagating errors. *Nature* 323: 533 - 536. <https://doi.org/10.1038/323533a0>
- Safdar Z, Sheng J, Usman Saeed M, Ramzan M, Al-Zubaidi A. 2025. Empowering cardiovascular diagnostics with SET-MobileNet: A lightweight and accurate deep learning-based classification approach. *Image Vision Computing* 162. <https://doi.org/10.1016/j.imavis.2025.105684>
- Tariq AB, Sajid MZ, Khan NA, Hamid MF, Ul-Haq A, Amjad J. 2025. An integrated deep learning framework using adaptive enhanced vision fusion and modified mobilenet architecture for precision classification of skin diseases with enhanced diagnostic performance. *SLAS Technology* 34. <https://doi.org/10.1016/j.slast.2025.100331>
- Tran TV, Nguyen TM, Lu QT. 2025. SMCS: A lightweight mobilenet-based framework for skin cancer classification, segmentation, and explanation, *Software Impacts*. <https://doi.org/10.1016/j.simpa.2025.100804>
- Warmuzek M, Zelawski M, Jałocha T. 2021. Application of the convolutional neural network for recognition of the metal alloys microstructure constituents based on their morphological characteristics. *Computational Materials Science* 199. <https://doi.org/10.1016/j.commatsci.2021.110722>
- Wythoff BJ. 1993. Backpropagations neural networks a tutorial. *Chemometrics Intelligent Laboratory Systems* 18: 115 - 155. [https://doi.org/10.1016/0169-7439\(93\)80052-J](https://doi.org/10.1016/0169-7439(93)80052-J)