

Modelación de la vida útil de los materiales mediante la metodología de superficie de respuesta y redes neuronales artificiales

Material lifespan modelling using response surface methodology and artificial neural networks

J.L. Fernandez-Delgadillo ^{a,*}, J. Medina-Marín ^a, I. Barragán-Vite ^a, N. Hernández-Romero ^a, J.C. Seck-Tuoh-Mora ^a

^a Área Académica de Ingeniería y Arquitectura, Universidad Autónoma del Estado de Hidalgo, Ciudad del Conocimiento, 42184, Pachuca, Hidalgo, México

Resumen

La predicción de la vida útil de los materiales representa un rasgo fundamental que permite optimizar la eficiencia operativa, disminución de costos y la inexistencia de fallos inesperados en los procesos industriales. En el estudio de esta investigación se lleva a cabo una comparación entre dos enfoques predictivos: la RSM (metodología de superficie de respuesta) y las RNA (redes neuronales artificiales), con el objetivo de determinar cuál de ellas ofrece un rendimiento más confiable al predecir la vida útil de los materiales, para la cual se hizo uso de una base de datos pública que recopila información que contiene las variables y defectos estructurales de los materiales. Ambas metodologías fueron ejecutadas valiéndose de métricas estadísticas, los resultados muestran que el modelo basado en RNA superó de manera notable al modelo RSM presentando mayor capacidad de precisión. En síntesis, las redes neuronales artificiales producirán la opción más eficiente a la hora de predecir la vida útil de los materiales industriales.

Palabras Clave: Predicción, Vida útil, Redes neuronales artificiales, Superficie de respuesta, Estadísticas.

Abstract

Predicting the useful life of materials is a fundamental feature that allows for the optimization of operational efficiency, cost reduction, and the elimination of unexpected failures in industrial processes. This research study compares two predictive approaches: RSM (response surface methodology) and ANN (artificial neural networks), with the aim of determining which one offers the most reliable performance in predicting the useful life of materials. To this end, a public database was used that compiles information containing the variables and structural defects of materials. Both methodologies were executed using statistical metrics, and the results show that the ANN-based model significantly outperformed the RSM model, demonstrating greater accuracy. In summary, artificial neural networks will produce the most efficient option when predicting the useful life of industrial materials.

Keywords: Prediction, Lifetime, Artificial neural networks, Response surface, Statistics.

1. Introducción

La predicción de la vida útil restante (RUL, por sus siglas en inglés) se ha vuelto una herramienta clave para la administración del mantenimiento industrial, ya que esta se

encuentra directamente relacionada con el monitoreo del desgaste gradual de los componentes. Este tipo de predicciones se basan en la recopilación de datos provenientes de sensores los cuales permiten examinar señales, como por ejemplo las vibraciones, con el fin de valorar el estado de los

*Autor para la correspondencia: fe351926@uaeh.edu.mx

Correo electrónico: fe351926@uaeh.edu.mx (Juan Luis Fernandez Delgadillo), jmedina@uaeh.edu.mx (Joselito Medina Marín), irvingb@uaeh.edu.mx (Irving Barragán Vite), nhromero@uaeh.edu.mx (Norberto Hernández Romero), jseck@uaeh.edu.mx (Juan Carlos Seck Tuoh Mora).

Historial del manuscrito: recibido el 04/11/2025, última versión-revisada recibida el 08/05/2026, aceptado el 10/07/2026, en línea (postprint) desde el 20/08/2026, publicado el 05/01/2027. **DOI:** <https://doi.org/10.29057/icbi.v14i28>.



componentes y anticipar fallos potenciales antes de que ocurran (Ferreira & Gonçalves, 2022). En este marco, se han desarrollado diversas estrategias para afinar la precisión de las predicciones, entre ellas, la metodología de superficies de respuesta, también conocida como RSM, la cual es una potente herramienta estadística empleada en el diseño de experimentos que permite examinar la relación matemática entre variables de entrada y salida con un número limitado de pruebas. Puede implementarse de manera efectiva cuando una o más respuestas están afectadas por múltiples variables independientes (Ray et al., 2021). Igualmente, las redes neuronales artificiales (RNA), que procesan datos mediante el entrenamiento de varios parámetros y producen resultados complejos a partir de entradas experimentales. Esta última ha demostrado ser particularmente provechosa en áreas como la bioquímica, la biología y la ingeniería química, por su capacidad de conectar resultados empíricos con teorías subyacentes (Muhammad et al., 2021).

El valor de prever con exactitud el RUL se basa en su capacidad para brindar información crucial sobre el momento en que un sistema llegará al final de su vida útil. Esto hace posible que los encargados de mantenimiento anticiparse a fallos inesperados y disminuyan considerablemente los costos relacionados al ciclo de vida de los equipos. Este enfoque está ejemplificado en algunos estudios recientes, como (Fernando, 2023) desarrolló un modelo de aprendizaje automático para estimar la vida útil de baterías de ion litio en bicicletas eléctricas; mientras que (Vázquez-Flores, 2024) propuso el uso de modelos basados en árboles de decisión y redes neuronales para evaluar la propagación del daño en turbinas de avión, utilizando datos del sistema C-MAPSS, con el fin de optimizar decisiones de mantenimiento predictivo.

El desarrollo de la inteligencia artificial (IA) ha posibilitado una mejora adicional de estos modelos. (Najjar et al., 2022) por ejemplo, desarrolló un modelo que combina memoria a largo plazo (LSTM) con un algoritmo de optimización Chimp (CHOA) para predecir características de calidad en procesos de corte por láser. Este tipo de aproximaciones requieren no solo la estimación puntual del RUL, sino también la incorporación de medidas de incertidumbre, como los intervalos de confianza (IC), los cuales pueden calcularse mediante métodos estadísticos como el Bootstrap (She & Jia, 2021). De acuerdo con (Shi & Chehade, 2021) estos métodos son generalmente más precisos, rápidos y económicos que los modelos tradicionales basados en la física, y presentan la ventaja adicional de no requerir una comprensión física detallada del sistema en estudio.

Dentro del marco del mantenimiento basado en la condición (CBM), que tiene como objetivo programar actividades de reparación de acuerdo al estado real de los equipos, la predicción del RUL representa una tecnología clave. (Zhang et al., 2022) subraya su función en la mejora de la fiabilidad y seguridad de los equipos industriales. Por su parte, las RNA se establecen como una herramienta altamente adaptable y flexible, capaces de aprender patrones complejos sin estar limitadas por restricciones mecánicas (Li et al., 2022). Su arquitectura, la cual se basa en el funcionamiento de las neuronas humanas (Qamar & Zardari, 2023) ha originado versiones como la unidad recurrente cerrada bidireccional (Bigru). Esta última utiliza mecanismos de reinicio y

actualización para mejorar el flujo de información (Lee & Singh, 2023).

Asimismo, la inteligencia artificial se ha descrito en términos generales como la habilidad de duplicar funciones cognitivas humanas, como el aprendizaje o la resolución de problemas, fundamentales para tareas de predicción (Entezari et al., 2023). Con el objetivo de reforzar estas proyecciones, se emplean métodos como el bootstrap para crear inferencias estadísticas a partir de los datos disponibles (Rousselet et al., 2023) lo que mejora la exactitud y la solidez de los modelos. Hoy en día, los fabricantes enfrentan al desafío del envejecimiento progresivo de sus equipos, lo cual tiene el potencial de deteriorar negativamente el rendimiento o incluso provocar la interrupción total de las líneas de producción (Kang et al., 2021). Al mismo tiempo, la implementación de métodos de mejora de calidad (QI) contribuye a mantener estándares de producción con una mínima pérdida de rendimiento (Psarommatas et al., 2021).

En este estudio, tomando en cuenta lo mencionado anteriormente, se tiene como propósito comparar la efectividad predictiva de dos enfoques: Para proyectar la vida útil de los materiales industriales, se emplea la metodología de superficies de respuesta (RSM) y redes neuronales artificiales (RNA). Esta comparación se llevará a cabo mediante el estudio de variables fundamentales relacionadas con la composición, el proceso de fabricación y las fallas estructurales de los materiales, con el fin de determinar cuál de los métodos proporciona una predicción más precisa y útil para la toma de decisiones.

2. Materiales y métodos.

Con el propósito de predecir la vida útil de componentes industriales mediante técnicas de inteligencia artificial, se llevó a cabo un estudio en el cual se utilizaron redes neuronales artificiales (RNA) y la metodología de superficie de respuesta (RSM). Los datos experimentales fueron obtenidos de la base de datos pública de Kaggle (Raza Owner, s. f.), la cual proporciona información de los componentes sometidos a distintos procesos de fabricación y operación.

Tabla 1: Variables de entrada y su descripción para el modelo predictivo.

Variable	Descripción
X1	Clasificación del componente.
X2	Configuración de grano microestructural.
X3	Tasa de enfriamiento durante la fabricación.
X4	Duración del enfriamiento (en segundos).
X5	Tiempo de forjado (en segundos).
X6	Tiempo del tratamiento térmico (en minutos)
X7	Porcentaje de níquel presente en el material
X8	Porcentaje de hierro presente en el material.
X9	Porcentaje de cobalto presente en el material
X10	Porcentaje de cromo presente en el material
X11	Número de defectos menores detectados
X12	Número de defectos mayores detectados
X13	Número de defectos localizados en los bordes del componente

X14	Ubicación inicial en el proceso de formación
X15	Método de fundición utilizado en el proceso

Importante: Las variables indicadas en la tabla representan los factores estructurales, composicionales y de proceso que fueron tomados en cuenta como entradas en el modelo predictivo. Cada una de ellas influye en el comportamiento y la vida útil del componente.

ambas con un nivel de confianza del 95 %. También se aplicó el método de Dunnett para comparar los tratamientos respecto a un control basado en los valores promedio reportados en la industria.

Tabla 2: Resumen estadístico descriptivo de las variables utilizadas en el modelo predictivo.

Variables	Datos							
X1	1461.797	1825.977	707.101	1086.37	1813.529	651.53	1803.015	1545.105
X2	3	2	1	3	1	4	2	2
X3	2	3	2	1	1	1	2	2
X4	12.836	19.032	28.418	9.084	16.196	28.178	19.146	16.223
X5	3.803	2.593	0.772	1.99	4.092	4.496	2.754	1.496
X6	6.515	3.521	1.327	2.201	3.881	3.871	4.339	9.422
X7	47.005	45.246	9.639	20.009	15.904	17.942	56.435	51.182
X8	65.45	54.162	52.565	56.665	60.502	49.471	64.557	53.483
X9	16.618	34.916	36.486	23.436	26.995	33.916	17.653	36.466
X10	16.51	6.063	8.927	17.04	11.382	12.389	16.813	8.869
X11	0.938	4.292	3.355	2.827	1.564	3.928	1.738	1.089
X12	10	19	35	0	10	21	18	21
X13	0	0	3	1	0	4	0	0
X14	0	0	0	0	0	0	0	0
X15	1	1	1	2	2	2	1	1
X16	2	3	3	1	2	3	2	1

Posteriormente, se creó un conjunto de datos experimentales diferentes a partir de esta información. Para llevar a cabo la modelación del comportamiento de los materiales y predecir su vida útil, se aplicaron las técnicas de ajuste de datos RSM y RNA. Finalmente, se seleccionó el modelo con mejor desempeño para identificar las combinaciones óptimas de variables que prolongan la vida útil de los componentes.

2.1. Preparación y procesamiento de los datos

La base de datos de Kaggle (Raza Owner, s. f.), fue sometida a un proceso de limpieza y normalización de variables. Se verificó la integridad de los datos, eliminando valores atípicos, datos incompletos y otorgándoles valores cuantitativos a ciertas características. Se clasificaron los componentes en diferentes grupos según el tipo de estructura (por ejemplo, válvula, bloque, tobera, cuchilla y el método de formación utilizado (forja, extrusión, colada continua, etc.).

Adicionalmente, se simularon condiciones operativas mediante variaciones controladas en parámetros como la tarifa de enfriamiento y el tiempo de proceso de calor, para reflejar distintas condiciones industriales. El objetivo fue construir un conjunto robusto de datos que permitiera entrenar y validar los modelos predictivos. Las mediciones y registros se centraron en variables cuantitativas relacionadas con la degradación estructural, y se analizaron mediante un ANOVA unidireccional y la prueba de comparación múltiple de Tukey,

2.2. Técnica de ajuste de datos

2.2.1 Metodología de superficie de respuesta

La Metodología de la Superficie de Respuesta (RSM) se utilizó para evaluar la influencia de la variable de entrada sobre la vida útil proyectada de los componentes, el modelado de los datos obtenidos de 1001 observaciones experimentales permitió generar ecuaciones cuadráticas que describen la relación entre las características del material y su tiempo estimado de fallo.

Los ajustes y análisis se realizaron utilizando los comandos nftool de red neuronal y fitlm de regresión lineal en la caja de herramientas estadísticas de MATLAB versión online. Se creó un modelo matemático principal para la variable de respuesta, vida útil en horas (X_1). La formulación de estos modelos parte del modelo cuadrático de la superficie de respuesta, el cual se presenta en la (ecuación 1).

$$f = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{j=2}^k \sum_{i=1}^{j-1} \beta_{ij} x_i x_j + \sum_{i=1}^k \beta_{ii} x_i^2 + e$$

En esta ecuación β_0 corresponde al valor constante, β_i indica el coeficiente asociado al término lineal, β_{ij} define el coeficiente de interacción entre variables, β_{ii} señala el

coeficiente del término cuadrático, X_i y X_j representan los factores independientes, y e denota el error del modelo.

El modelo cuadrático permite examinar los efectos lineales y de curvatura en la relación entre las variables independientes y la variable de respuesta, en este caso, la vida útil de los materiales. La intersección (β_0) representa el valor estimado de la vida útil cuando todas las variables independientes son cero. Los términos lineales (β_i) reflejan los efectos directos de cada variable, mientras que los términos cuadráticos (β_{ii}) representan la curvatura en la superficie de respuesta, indicando cómo varía la respuesta cuando se modifican los valores de entrada. El coeficiente de interacción (β_{ij}) expresa el efecto combinado entre dos variables independientes, mostrando si existe una relación sinérgica que no puede explicarse por sus efectos individuales. Estos coeficientes se obtienen mediante análisis de regresión aplicado a los datos experimentales (Velázquez-De-Lucio et al., 2023).

Importante: La tabla es una muestra representativa del conjunto de datos utilizado para el análisis predictivo, donde X_1 corresponde a la variable de respuesta (horas previstas de vida útil del componente) $X_2 - X_{16}$ representan las variables de entrada relacionadas con las características del material y el proceso de fabricación. Se presentan únicamente 8 observaciones como ejemplo ilustrativo. La tabla completa se encuentra en el siguiente enlace: https://docs.google.com/spreadsheets/d/1B_gIMGX9DD2LlbVRXEQ57cKAJ1jxssRX/edit?usp=drive_link&ouid=100560313961019019937&rtpof=true&sd=true

Para evaluar la validez de los modelos de superficie de respuesta generados, se realizó un análisis de varianza (ANOVA), con el fin de comprobar tanto la adecuación del ajuste como la significancia estadística de los coeficientes de regresión involucrado en el modelo propuesto.

2.2.2 Red Neuronal Artificial

El método RNA, que simula las capacidades de procesamiento biológico del cerebro humano. Es capaz de simular y modelar sistemas no lineales extremadamente complejos. Una matriz de información que una RNA ha entrenado con éxito puede conducirse para pronosticar los hallazgos de nuevos detalles de entrada (Alardhi et al., 2024).

Para llevar a cabo el desarrollo del modelo de RNA también se utilizó el software Matlab versión online. La variable de respuesta fue la vida útil del material (en horas), mientras que las variables de entrada correspondieron a las 15 características descritas previamente (ver Tabla 2), que incluyen aspectos relacionados con la composición química, el tipo de componente, los procesos térmicos y la presencia de defectos.

Se desarrolló un modelo de red neuronal artificial, cuya capa de entrada estuvo compuesta por 16 neuronas, una por cada variable de entrada, y una capa de salida con una sola neurona, que representa la predicción de la vida útil del material en horas. Para determinar la configuración óptima del modelo, se entrenaron distintas arquitecturas con una a tres

capas ocultas, y un número aleatorio de una a diez neuronas por capa, utilizando un algoritmo de búsqueda local.

Para el entrenamiento del modelo, se utilizaron 1001 muestras en total, de las cuales el 70 % (701 muestras) se destinó al entrenamiento, el 15 % (150 muestras) a la validación y el 15 % restante (150 muestras) a la prueba. Esta partición aleatoria se aplicó con el fin de evitar el sobreajuste y garantizar un desempeño robusto del modelo. Durante el proceso de entrenamiento, se utilizó la función de transferencia tangente hiperbólica en las capas ocultas, debido a su capacidad para representar relaciones no lineales complejas, mientras que en la capa de salida se empleó una función de transferencia lineal. La tasa de aprendizaje fue configurada en 0.01 y el número de épocas en 1000. El modelo fue entrenado utilizando el algoritmo de retropropagación con descenso por gradiente, lo que permitió una optimización eficiente de los pesos de la red neuronal.

2.3. Idoneidad comparativa entre los modelos RSM y RNA

El coeficiente de determinación (R^2) (ecuación 2), el error cuadrático medio (RMSE) (ecuación 3) y el error porcentual absoluto medio (MAPE) (ecuación 4) son las métricas aplicadas para evaluar el rendimiento de los modelos RSM y RNA.

$$R^2 = \frac{\sum_{i=1}^n (A_i - \bar{A}_i)(F_i - \bar{F}_i)^2}{\sum_{i=1}^n (A_i - \bar{A}_i)^2 (F_i - \bar{F}_i)^2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - A_i)^2}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|A_i - F_i|}{A_i}$$

Donde n es el número de valores, A_i es el valor real y F_i es el valor previsto con el modelo RSM o RNA. Se utilizaron el RMSE y el MAPE más bajos y el R^2 más alto para identificar los modelos con el mejor rendimiento.

3. Resultados

3.1. Metodología de superficie de respuesta

Se desarrolló el modelo de Superficie de Respuesta (RSM) y se trazaron los gráficos de correlación lineal para evaluar el ajuste del modelo en relación con la vida útil del material (Figura 1). El modelo cuadrático presentó el mejor ajuste al capturar tanto los efectos lineales como los de curvatura presentes en los datos analizados.

En la (ecuación 5), y representa la variable de respuesta (vida útil del material), β_0 corresponde al término independiente, β_i los coeficientes lineales, β_{ii} los coeficientes cuadráticos, β_{ij} los coeficientes de interacción entre variables,


x_i y x_j las variables independientes, y e el término de error. Estos resultados sirvieron como base para validar la consistencia de los datos y facilitar su posterior integración en el modelo de red neuronal artificial.

$$y = \beta_0 + \sum_{i=1}^{15} \beta_i x_i + \sum_{i=1}^{15} \beta_{ii} x_i^2 + \sum_{i < j}^{15} \beta_{ij} x_i x_j + e = -84613$$

El análisis de varianza (ANOVA) para el modelo cuadrático de superficie de respuesta muestra la influencia de las dos variables independientes x_1 y x_2 sobre la variable de respuesta asociada a la vida útil del material. El ANOVA del modelo desarrollado para representar el comportamiento del material en función del tiempo y las condiciones de prueba se presenta en la Tabla 3, con un valor de Fisher de 36.3 y un valor p significativamente inferior a 0.0001. El coeficiente de determinación R^2 obtenido al comparar los datos experimentales con los valores predichos fue de 0.819068, lo que indica que más del 80% de la variabilidad de los datos fue explicada correctamente por el modelo (Figura 1).

RSM logra replicar de forma adecuada la tendencia general, lo que indica un buen grado de ajuste predictivo. A partir de estos resultados, se confirma que el modelo de superficie de respuesta es adecuado para predecir el comportamiento de degradación del material, aunque no dando los mejores resultados de ajuste para una correcta predicción, considerando tanto su composición como el tiempo de exposición bajo condiciones controladas.

Figura 2: Gráfica comparativa entre los valores experimentales y los valores predichos por el modelo de Superficie de Respuesta (RSM).




3.2.

Tabla 3: ANOVA del modelo cuadrático RSM para la predicción de la vida útil de los materiales.

	Suma de Cuadrados	Grados de Libertad	Cuadrático Medio	Valor-f	Valor-p
Total	116090680.61200	999	116206.8874995	36.301988165787	4.7496426009046 6 e-276
Modelo	98304310.790253	132	744729.6271988 87	36.30198817	4.7496426009046 6 e-276
Lineal	20700025.810217	15	1380001.7206811	67.26844791	6.7557007004883 3e-134
No lineal	77604284.98003 53	117	663284.487	32.33192922	
Residual	17786369.82	867	20514.84409		

El error cuadrático medio (RMSE) fue de 133.3655496 y el error porcentual absoluto medio (MAPE) fue de 9.1484%.

Figura 1: Gráfico RSM con ajuste cuadrático del modelo y correlación lineal.




De igual manera se realizó una gráfica en la cual presenta la comparación entre los valores reales y los estimados por el (RSM) para la vida útil de los materiales, a lo largo de las 1001 muestras. Se observa que, a pesar del comportamiento altamente variable y no lineal de los datos reales, el modelo

Red neuronal artificial

Teniendo en cuenta el coeficiente de determinación (R^2), el error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE), se identificó la red neuronal artificial (RNA) con el mejor desempeño en la predicción de la vida útil de los materiales. Su estructura presenta una mayor capacidad de generalización y ajuste a los datos experimentales, lo que la convierte en herramienta confiable para modelar el deterioro del material en función de cada una de sus variables.

La RNA con la mejor capacidad y aptitud para la predicción de la vida útil de los materiales sería ($R^2 = 0.968992$, RMSE= 59.4545183, MAPE= 3.5066%). Mismo que su estructura está compuesta por una capa de entrada con 15 neuronas, tres capas ocultas, una con 7, la siguiente con 3 y la última con 3 neuronas respectivamente, obteniendo una capa de salida con 1 sola neurona que representa la vida útil en horas estimada del material. Los datos reales se compararon con los datos predichos para verificar la adecuación de los modelos RNA. (Ray et al., 2021)

Figura 3: Arquitectura de RNA del modelo para la predicción de la vida útil de los materiales.



lo que indica un ajuste confiable y una alta capacidad de generalización frente a la variabilidad inherente de los materiales analizados.

Tabla 4: Comparación de modelos.

Enfoque	Coefficiente de determinación R^2	Error Cuadrático Medio (RMSE)	Error porcentual absoluto medio (MAPE)	Tiempos de Procesamiento (segundos)	Aporte
RSM	0.819068	133.3655496	9.1484%	1.8447	Modelo estadístico basado en regresión polinómica que presenta una complejidad baja a media, requiere de datos estructurados y relativamente pequeños, obtenidos mediante diseños experimentales.
RNA	0.968992	59.4545183	3.5066%	3370.6285	Modelo computacional inspirado en el cerebro humano capaz de aprender patrones no lineales complejos, tiene una complejidad alta debido al ajuste de múltiples parámetros, requiere grandes volúmenes de datos variados para lograr un buen entrenamiento y alta precisión.

De igual manera que en la Superficie de respuesta RSM, se realizó una gráfica en la que se presenta la comparación entre los valores reales de la vida útil de los materiales y los valores predichos mediante la red neuronal artificial (RNA). Como se observa, la línea correspondiente al modelo de RNA sigue de manera más cercana la tendencia de los datos reales a lo largo de las 1001 muestras analizadas en la Figura 5. Esta alta correspondencia visual sugiere un desempeño robusto del modelo para capturar la complejidad del fenómeno estudiado. La capacidad de la RNA para aproximarse con precisión a los valores reales respalda su utilidad como herramienta predictiva eficaz, especialmente en sistemas donde intervienen múltiples variables con interacciones no lineales. El modelo mostró menor dispersión y una mejor alineación, como se muestra en la Figura 4 con los datos experimentales,

Figura 4: Gráfico RNA y correlación lineal para la predicción de la vida útil.





Figura 5: Desempeño predictivo de la (RNA) frente a los datos experimentales.



En síntesis, con base en nuestros resultados obtenidos se observa que el modelo basado en redes neuronales artificiales (RNA) presenta un desempeño superior a la hora de realizar las predicciones en comparación con la metodología de superficie de respuesta (RSM). Este modelo alcanzó los mejores indicadores de ajuste, con un coeficiente de determinación ($R^2=0.968992$), un error cuadrático medio ($RMSE = 59.4545183$) y un error porcentual absoluto medio ($MAPE = 3.5066\%$). La arquitectura óptima de la RNA estuvo conformada por una capa de entrada con 15 neuronas, tres capas ocultas con 7, 3 y 3 neuronas, respectivamente, y una capa de salida con una sola neurona, encargada de estimar la vida útil del material, como se muestra en la Figura 3.

4. Discusión de Resultados

La (RSM) es una colección de técnicas estadísticas y matemáticas útiles para desarrollar, mejorar y optimizar procesos, con aplicaciones importantes en el diseño, desarrollo y formulación de nuevos productos, así como en la mejora de los diseños de productos existentes. (Rodríguez-Medina et al., 2025)

Los resultados obtenidos evidencian una diferencia significativa en el desempeño predictivo entre la (RSM) y las (RNA). El modelo RSM, ha arrojado valiosos resultados para el modelado de datos en las últimas décadas. (Shokri & Ghaemi, 2024). Aunque logró verlo como una tendencia general de vida útil de los materiales, mostró un coeficiente de determinación moderado ($R^2 = 0.819$), con un error cuadrático medio (RMSE) de 133.36 y un error porcentual absoluto medio (MAPE) de 9.15%. Estos valores indican que, si bien el modelo es capaz de explicar gran parte de la variabilidad de los datos, su capacidad para predecir con precisión casos individuales se ve limitada, probablemente debido a la naturaleza altamente no lineal e interactiva de las variables que se pueden interrelacionar.


Por otro lado, el modelo de RNA obtuvo un rendimiento notablemente superior, con un R^2 de 0.969, un RMSE de 59.45 y un MAPE de 3.51%. El paradigma de las RNA se basa en la búsqueda de diferentes patrones en los datos y la identificación de cualquier diferencia para determinar el patrón que obtenga el resultado deseado. (Saber et al., 2023). Por la razón anterior, la mejora sustancial en las métricas muestra la capacidad de las RNA para modelar relaciones complejas y no lineales entre las variables de entrada y la vida

útil estimada, sin la necesidad de imponer supuestos paramétricos estrictos como en RSM. Los resultados de ambos modelos se muestran en la Tabla 4, misma que presenta una comparación integral considerando métricas de desempeño y características operativas de cada enfoque. En términos de precisión, el modelo RNA mostró un rendimiento superior en comparación del modelo RSM. No obstante, esta mejora en la capacidad predictiva implica un mayor costo computacional, reflejado en un tiempo de procesamiento considerablemente más alto para la RNA (3370.6285 s), que es el tiempo total en el cual fueron entrenadas las 1110 configuraciones, obteniendo el promedio por cada configuración es de 3.03 s, respectivamente, frente a la RSM con (1.8447 s), ya que en este método únicamente se ejecuta el comando y no se arroja el promedio.

Concretamente, los resultados indican que la implementación de RNA para la predicción de la vida útil de materiales industriales ofrecen estimaciones más precisas y, por ende, decisiones de mantenimiento más eficientes y oportunas. No obstante, cabe mencionar que el entrenamiento de RNA requiere un mayor esfuerzo computacional y una elección adecuada de hiperparámetros para evitar problemas como el sobreajuste. Es por ello que, con el propósito de mejorar la interpretación del desempeño de los modelos, se incorporó un análisis de residuos, en el cual se representa la diferencia entre los valores predichos y los valores reales para cada observación, tanto en el modelo de redes neuronales artificiales (RNA) como en la metodología de superficie de respuesta (RSM). En este caso, los residuos fueron calculados como la resta del valor estimado menos el valor observado, de manera que valores cercanos a cero indican una mayor precisión del modelo. A partir de la representación gráfica de dichos residuos, se observa que la dispersión asociada al modelo RNA se mantiene más próxima a la línea de referencia en cero, lo que evidencia un menor error de predicción y una mejor capacidad de ajuste en comparación con el modelo RSM, cuyos residuos presentan una mayor variabilidad. Este comportamiento confirma la superioridad del modelo basado en RNA para capturar la complejidad de los datos analizados, como se muestra en la Figura 6.

Finalmente, ambas técnicas pueden ser usadas para propósitos predictivos, pero las RNA se centran más en el modelado de relaciones complejas, mientras que RSM se ocupa de la estimación y la experimentación eficiente para la optimización. (Khoshraftar, 2025). Aunque los resultados favorecen la propuesta de RNA en relación a RSM para los datos utilizados, investigaciones futuras podrían considerar métodos de combinación entre la interpretabilidad de RSM y la capacidad predictiva de RNA, así como validar los modelos en escenarios experimentales adicionales y con datos provenientes de distintas condiciones operativas.

Figura 6: Distribución de residuos de los modelos RNA y RSM.



5. Conclusiones

El presente estudio comparó el desempeño de la Metodología de Superficie de Respuesta (RSM) y las Redes Neuronales Artificiales (RNA) en la predicción de la vida útil de materiales industriales, empleando un conjunto de datos con características específicas. Los resultados evidenciaron que el modelo basado en RNA logró un ajuste sustancialmente superior, con un coeficiente de determinación R^2 alto y adecuado (cercano a 1). Esto también se verificó mediante valores de RMSE y MAPE en el cual la RSM mantuvo su valor como herramienta estadística de referencia presentando valores inferiores. Aunque en este caso las RNA superaron ampliamente a la RSM, se reconoce el carácter complementario de ambas metodologías.

La implementación de modelos avanzados de inteligencia artificial ofrece a la industria la posibilidad de anticipar el deterioro de los componentes, optimizar estrategias de mantenimiento y prolongar la vida operativa de los equipos. El aporte central de este trabajo radica en demostrar que la selección del modelo no debe basarse únicamente en su formulación matemática, sino también en su capacidad para responder a las necesidades reales de operación. En este sentido, integrar la interpretabilidad de la RSM con la capacidad de aprendizaje de las RNA podría representar un avance significativo, aportando soluciones más completas y sostenibles para la gestión de activos industriales. Gracias a este estudio se contribuye a la literatura al demostrar empíricamente la superioridad de las RNA sobre las RSM en cuanto a la predicción se refiere, usando datos experimentales reales.

Agradecimientos

En calidad de autor de correspondencia, yo, Juan Luis Fernández Delgadillo, expreso mi más profundo y distinguido agradecimiento al Dr. Joselito Medina Marín por su invaluable apoyo, orientación académica y constantes aportaciones durante el desarrollo de la presente investigación. Su experiencia, conocimiento científico y disposición fueron elementos fundamentales para la consolidación de este trabajo.

De igual manera, extendiendo mi reconocimiento y agradecimiento a todos los coautores participantes, por su dedicación y valiosa colaboración que resultaron esenciales para el éxito del presente artículo.

Referencias

- Acosta González, D. (2023). Predicción de la vida útil remanente de la batería de un vehículo de movilidad sostenible. Universidad de Antioquia. Disponible en: <https://hdl.handle.net/10495/37623>
- Alardhi, S. M., Salman, A. D., Breig, S. J. M., Jaber, A. A., Fiyadh, S. S., AlJaberi, F. Y., Nguyen, D. D., Van, B., & Le, P. (2024). Artificial neural network and response surface methodology for modeling reverse osmosis process in wastewater treatment. *Journal Of Industrial And Engineering Chemistry*, 133, 599-613. <https://doi.org/10.1016/j.jiec.2024.02.039>
- Entezari, A., Aslani, A., Zahedi, R., & Noorollahi, Y. (2022). Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45, 101017. <https://doi.org/10.1016/j.esr.2022.101017>
- Ferreira, C., & Gonçalves, G. (2022). Remaining Useful Life prediction and challenges: A literature review on the use of Machine Learning Methods. *Journal Of Manufacturing Systems*, 63, 550-562. <https://doi.org/10.1016/j.jmsy.2022.05.010>
- Kang, Z., Catal, C., & Tekinerdogan, B. (2021). Remaining Useful Life (RUL) Prediction of Equipment in Production Lines Using Artificial Neural Networks. *Sensors*, 21(3), 932. <https://doi.org/10.3390/s21030932>

- Khoshraftar, Z. Modeling of CO₂ solubility and partial pressure in blended diisopropanolamine and 2-amino-2-methylpropanol solutions via response surface methodology and artificial neural network. *Sci Rep* 15, 1800 (2025). <https://doi.org/10.1038/s41598-025-86144-2>
- Lee, T., & Singh, V. P. (2023). Deep learning: Long short-term memory in hydrological time series. En *Elsevier eBooks* (pp. 49-67). <https://doi.org/10.1016/b978-0-12-821961-4.00022-1>
- Li, P., Zhang, Z., Grosu, R., Deng, Z., Hou, J., Rong, Y., & Wu, R. (2021). An end-to-end neural network framework for state-of-health estimation and remaining useful life prediction of electric vehicle lithium batteries. *Renewable And Sustainable Energy Reviews*, 156, 111843. <https://doi.org/10.1016/j.rser.2021.111843>
- Muhammad, G., Ngatcha, A. D. P., Lv, Y., Xiong, W., El-Badry, Y. A., Asmatulu, E., Xu, J., & Alam, M. A. (2022). Enhanced biodiesel production from wet microalgae biomass optimized via response surface methodology and artificial neural network. *Renewable Energy*, 184, 753-764. <https://doi.org/10.1016/j.renene.2021.11.091>
- Najjar, I., Sadoun, A., Elaziz, M. A., Abdallah, A., Fathy, A., & Elsheikh, A. H. (2022). Predicting kerf quality characteristics in laser cutting of basalt fibers reinforced polymer composites using neural network and chimp optimization. *Alexandria Engineering Journal*, 61(12), 11005-11018. <https://doi.org/10.1016/j.aej.2022.04.032>
- Psarommatis, F., Sousa, J., Mendonça, J. P., & Kiritsis, D. (2021). Zero-defect manufacturing the approach for higher manufacturing sustainability in the era of industry 4.0: a position paper. *International Journal Of Production Research*, 60(1), 73-91. <https://doi.org/10.1080/00207543.2021.1987551>
- Qamar, R., & Zardari, B. A. (2023). Artificial Neural Networks: An Overview. *Mesopotamian Journal Of Computer Science*, 130-139. <https://doi.org/10.58496/mjcs/2023/015>
- Ray, S., Haque, M., Ahmed, T., & Nahin, T. T. (2021). Comparison of artificial neural network (ANN) and response surface methodology (RSM) in predicting the compressive and splitting tensile strength of concrete prepared with glass waste and tin (Sn) can fiber. *Journal Of King Saud University - Engineering Sciences*, 35(3), 185-199. <https://doi.org/10.1016/j.jksues.2021.03.006>
- Raza Owner, A. (s. f.). Material Lifespan Prediction Dataset. Kaggle. Recuperado 25 de marzo de 11d. C., de <https://www.kaggle.com/datasets/aounraza/material-lifespan-prediction-dataset/data>
- Rodríguez-Medina, M. A., Martínez, G. G., Ríos, E. B. H., & Ojinaga, E. R. P. (2025). Optimización Robusta e Ingeniería Predictiva Vs. Arreglos Ortogonales, Metodología de Superficie de Respuesta, Diseño Central Compuesto y Respuesta Dual: Caso comparativo. *RIDE Revista Iberoamericana Para la Investigación y el Desarrollo Educativo*, 16(31). <https://doi.org/10.23913/ride.v16i31.2519>
- Rousselet, G., Pernet, C. R., & Wilcox, R. R. (2023). An introduction to the bootstrap: a versatile method to make inferences by using data-driven simulations. *Meta-Psychology*, 7. <https://doi.org/10.15626/mp.2019.2058>
- Saber, W. I. A., Ghoniem, A. A., Al-Otibi, F. O., El-Hersh, M. S., Eldadamony, N. M., Mena, F., & Elattar, K. M. (2023). A comparative study using response surface methodology and artificial neural network towards optimized production of melanin by *Aureobasidium pullulans* AKW. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-40549-z>
- She, D., & Jia, M. (2020). A BiGRU method for remaining useful life prediction of machinery. *Measurement*, 167, 108277. <https://doi.org/10.1016/j.measurement.2020.108277>
- Shi, Z., & Chehade, A. (2020). A dual-LSTM framework combining change point detection and remaining useful life prediction. *Reliability Engineering & System Safety*, 205, 107257. <https://doi.org/10.1016/j.res.2020.107257>
- Shokri, A., & Ghaemi, A. (2024). Developing artificial neural networks and response surface methodology for evaluating CO₂ absorption into K₂CO₃/piperazine solution. *Case Studies In Chemical And Environmental Engineering*, 9, 100725. <https://doi.org/10.1016/j.csee.2024.100725>
- Vázquez-Flores, R. C. (2024). Estimación del tiempo de vida de una turbina a través de redes neuronales y árboles de decisión. Trabajo de obtención de grado, Maestría en Ciencia de Datos. Tlaquepaque, Jalisco: ITESO. <https://hdl.handle.net/11117/10859>
- Velázquez-de-Lucio, BS, Álvarez-Cervantes, J., Serna-Díaz, MG, Hernández-Domínguez, EM, y Medina-Marin, J. (2023). Implementación de la metodología de superficie de respuesta y redes neuronales artificiales para determinar las mejores condiciones de germinación de *Lycopersicon esculentum* según su desarrollo fenológico en invernadero. *Agriculture*, 13 (12), 2175. <https://doi.org/10.3390/agriculture13122175>
- Zhang, Z., Song, W., & Li, Q. (2022). Dual-Aspect Self-Attention Based on Transformer for Remaining Useful Life Prediction. *IEEE Transactions On Instrumentation And Measurement*, 71, 1-11. <https://doi.org/10.1109/tim.2022.3160561>