

## Inteligencia artificial en la industria 4.0: Comparación de redes neuronales y superficies de respuesta para la detección de fallas

### Artificial intelligence in industry 4.0: Comparison of neural networks and response surfaces for fault detection

José E. Hernández Oropeza <sup>a</sup>, Joselito Medina Marín <sup>b</sup>, María G. Serna Díaz <sup>c</sup>, Juan C. Seck Tuoh Mora <sup>d</sup>, Norberto Hernández Romero <sup>e</sup>

#### Abstract:

This study analyzes the performance of Artificial Neural Networks (ANN) and Response Surface Methodology (RSM) for fault detection in industrial environments. Using a smart sensor dataset, both models were trained in MATLAB® and evaluated using metrics such as R<sup>2</sup> and RMSE. The results show that the ANN has greater predictive capability, while the RSM offers better interpretation of the variables. The combination of both techniques strengthens predictive maintenance within the context of Industry 4.0.

#### Keywords:

Industry 4.0, Smart Sensors, Neural Networks, Fault Detection, Predictive Maintenance

#### Resumen:

Este estudio analiza el desempeño de las Redes Neuronales Artificiales (RNA) y la Metodología de Superficie de Respuesta (MSR) para la detección de fallas en entornos industriales. Utilizando una base de datos de sensores inteligentes, ambos modelos fueron entrenados en MATLAB® y evaluados con métricas como R<sup>2</sup> y RMSE. Los resultados muestran que la RNA posee una mayor capacidad predictiva, mientras que la MSR ofrece mejor interpretación de las variables. La combinación de ambas técnicas fortalece el mantenimiento predictivo en el contexto de la Industria 4.0.

#### Palabras Clave:

Industria 4.0, Sensores inteligentes, Redes Neuronales, Detección de fallas, Mantenimiento predictivo

### Introducción

En el entorno industrial actual, la eficiencia operativa y la reducción de costos de mantenimiento son factores

críticos para la competitividad. Sin embargo, muchas industrias continúan enfrentando paros no programados y pérdidas significativas debido a fallas inesperadas en sus equipos. Estos incidentes, además de comprometer

<sup>a</sup> Autor de Correspondencia, Universidad Autónoma del Estado de Hidalgo | Instituto de Ciencias Básicas e Ingenierías | Pachuca de Soto-Hidalgo | México, <https://orcid.org/0009-0008-3695-7919>, Email: [he440509@uaeh.edu.mx](mailto:he440509@uaeh.edu.mx)

<sup>b</sup> Universidad Autónoma del Estado de Hidalgo | Instituto de Ciencias Básicas e Ingenierías | Pachuca de Soto-Hidalgo | México, <https://orcid.org/0000-0003-0937-8707>, Email: [jmedina@uaeh.edu.mx](mailto:jmedina@uaeh.edu.mx)

<sup>c</sup> Universidad Autónoma del Estado de Hidalgo | Instituto de Ciencias Básicas e Ingenierías | Pachuca de Soto-Hidalgo | México, <https://orcid.org/0000-0002-2846-6908>, Email: [sedg0210@yahoo.com](mailto:sedg0210@yahoo.com)

<sup>d</sup> Universidad Autónoma del Estado de Hidalgo | Instituto de Ciencias Básicas e Ingenierías | Pachuca de Soto-Hidalgo | México, <https://orcid.org/0000-0003-3678-1120>, Email: [jseck@uaeh.edu.mx](mailto:jseck@uaeh.edu.mx)

<sup>e</sup> Universidad Autónoma del Estado de Hidalgo | Instituto de Ciencias Básicas e Ingenierías | Pachuca de Soto-Hidalgo | México, <https://orcid.org/0000-0001-9942-306X>, Email: [nhromero@uaeh.edu.mx](mailto:nhromero@uaeh.edu.mx)

la seguridad y la productividad, generan elevados costos de reparación y tiempos de inactividad. En este contexto, la anticipación de fallas se ha convertido en una necesidad estratégica más que en una opción.

El concepto de Industria 4.0 tiene como objetivo crear fábricas inteligentes donde se implementan e integran tecnologías de fabricación como sistemas cibernéticos, el Internet de las cosas (IOT, por sus siglas en inglés), cómputo en la nube, grandes datos o big data, Analítica, entre otras. De tal forma que la nueva era tecnológica está transformando las cadenas de valor de la industria. (Hernández, 2021)

En la era actual de la Industria 4.0, la integración de tecnologías avanzadas está redefiniendo los paradigmas industriales, ofreciendo oportunidades sin precedentes para mejorar la eficiencia y la confiabilidad de los procesos. Este informe se adentra en la convergencia de la Industria 4.0 con dos elementos fundamentales: el Análisis de Causa Raíz (RCA) y el Mantenimiento Centrado en Confiabilidad (RCM). (Castro, 2023)

En su trabajo (Castro, 2023) comprueba que el RCA, esencial para identificar las causas fundamentales de los problemas operativos, se fusiona con el RCM, que busca maximizar la disponibilidad y prolongar la vida útil de los activos. La simbiosis de estas disciplinas con las herramientas de la Industria 4.0 ofrece un terreno fértil para la mejora continua y la toma de decisiones informada entorno a las empresas industriales.

En su investigación (Castro, 2023) demuestra que Las tecnologías del mantenimiento 4.0, como la inteligencia artificial, el aprendizaje automático, la realidad aumentada y el gemelo digital, ofrecen a las empresas una serie de oportunidades para mejorar la productividad y la confiabilidad de sus activos. Estas tecnologías pueden utilizarse para automatizar tareas de mantenimiento, como el análisis de datos, la detección de fallos y la planificación de intervenciones. También pueden utilizarse para proporcionar asistencia remota a los técnicos de mantenimiento y para mejorar la seguridad en las tareas de mantenimiento.

En el trabajo de (Villalón, 2022) menciona que la integración de tres tecnologías: redes de sensores inalámbricos, almacenamiento de datos en la nube y aplicaciones móviles, juntas posibilitan su utilización en amplias aplicaciones en un mundo cada vez más envuelto en el Internet de las Cosas (IoT) y en la Industria 4.0.

En su artículo (Martínez, 2023) establece que las redes neuronales artificiales (RNA) han presentado un papel

importante con la entrada de la cuarta revolución industrial y las nuevas tecnologías para resolver problemas en diferentes áreas de la ingeniería industrial. Si bien la cuarta revolución industrial está muy ligada a la ingeniería industrial, las redes neuronales son muy complejas en comparación a los métodos tradicionales de control de procesos u optimización de procesos industriales. De acuerdo a su revisión bibliográfica el concluye que las RNA son utilizadas para predecir y ayudar a diferentes campos de estudio de la ingeniería industrial.

La implementación de sensores inteligentes y técnicas avanzadas de análisis de datos en la Industria 4.0 no solo mejora la eficiencia operativa, sino que también contribuye a reducir costos y aumentar la seguridad en los entornos industriales.

A partir de lo abordado en trabajos de otros autores afirmo que la detección de fallas en equipos industriales es un factor clave en la optimización de procesos dentro del marco de la Industria 4.0, donde el Internet de las Cosas (IoT) y los sensores inteligentes permiten la recopilación de grandes volúmenes de datos en tiempo real. Para mejorar la precisión en la identificación temprana de anomalías, es fundamental el uso de modelos estadísticos y de aprendizaje automático que permitan interpretar estos datos de manera eficiente.

En este estudio, se empleará una base de datos numérica obtenida de (Kaggle, 2021) para entrenar y evaluar dos enfoques distintos: redes neuronales artificiales y el método de superficie de respuesta. El objetivo principal es comparar el desempeño de ambos modelos en la detección de fallas, considerando métricas de precisión, sensibilidad y capacidad predictiva.

Mediante este análisis, se busca determinar cuál de estas metodologías ofrece una mayor relevancia en la detección temprana de fallas en equipos industriales, contribuyendo así a la implementación de estrategias de mantenimiento predictivo más efectivas en entornos industriales inteligentes.

Este trabajo tiene como objetivo simular, mediante el uso de MATLAB, el comportamiento de sensores industriales en un entorno controlado, y aplicar redes neuronales para predecir posibles fallas en los equipos. Con ello, se busca demostrar la aplicabilidad y efectividad de estas tecnologías en el ámbito del mantenimiento predictivo, contribuyendo así al desarrollo de procesos industriales más confiables, sostenibles y alineados con los principios de la Industria 4.0.

## **Internet de las cosas**

El Internet de las Cosas (IoT, por sus siglas en inglés) se refiere a una red global de objetos físicos y virtuales interconectados a través de Internet, capaces de recopilar, intercambiar y actuar sobre datos sin intervención humana directa. En relación a la Ingeniería es muy importante esto, ya que la maquinaria industrial al estar conectados con sensores, software y otras tecnologías que les permiten interactuar con su entorno y otros dispositivos, permite un autoaprendizaje por medio de programas que al proporcionarles una base de datos relativo a ello pueden predecir resultados futuros y dependiendo de ellos tomar la mejor decisión posible.

Según (Commission, 2024), el IoT es una infraestructura de red basada en la computación que permite la identificación única de objetos y su conexión a través de Internet, facilitando la recopilación y el intercambio de datos para actuar en función de la información recibida. Según (Shee, 2024) el IoT es una tecnología ubicua potenciada por etiquetas RFID integradas en dispositivos con capacidades inalámbricas, móviles y de detección, capaces de capturar y compartir datos de manera fluida en una red de información.

### Machine learning

El *machine learning*, también conocido como aprendizaje automático, es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos y modelos que permiten a los sistemas informáticos aprender y mejorar automáticamente a partir de la experiencia y los datos recopilados, sin necesidad de ser programados explícitamente. Este enfoque ha demostrado ser revolucionario en diversas industrias, ya que permite a las empresas tomar decisiones más informadas y eficientes, y automatizar tareas complejas que anteriormente requerían una gran cantidad de tiempo y recursos humanos.

En el contexto de la Industria 4.0, el *machine learning* se ha convertido en una herramienta esencial para la transformación digital de las empresas. Permite analizar grandes volúmenes de datos generados por sensores industriales, optimizar procesos de producción, predecir fallos en maquinaria y mejorar la calidad del producto.

### Industria 4.0

La Industria 4.0, también conocida como la Cuarta Revolución Industrial, representa una transformación significativa en los procesos de manufactura y producción mediante la integración de tecnologías digitales avanzadas.

Según (Moosavi, 2021) la Industria 4.0 es una transformación digital impulsada por las TI que mejora la correlación entre máquinas y humanos, e integra automatización, digitalización, interacción humana-máquina, intercambio automático de datos y comunicación continua en tiempo real.

Además, (Zhang, 2021) destacan que la Industria 4.0 no solo implica una evolución tecnológica, sino también un cambio estratégico en la gestión industrial, ya que permite la integración horizontal y vertical de los procesos, facilitando la creación de redes de valor globales más eficientes y adaptables.

Esta transformación digital ha sido impulsada por la necesidad de las industrias de adaptarse a un entorno altamente competitivo y en constante cambio, donde la capacidad de anticipar fallas y optimizar procesos se ha vuelto crucial para mantener la eficiencia operativa y la sostenibilidad.



Figura 1. Industria 4.0 con enfoque en sensores industriales e inteligencia artificial Fuente: Elaboración propia.

### Sensores inteligentes basados en el internet de las cosas

(Rosca, 2025) Define que los sensores inteligentes basados en el internet de las cosas (IOT) proporcionan datos en tiempo real en diversos entornos físicos, lo cual es posible gracias a la combinación de inteligencia artificial (IA) con tecnologías modernas de adquisición y procesamiento de datos.

Este concepto refleja claramente cómo IoT e IA juntos están transformando el entorno físico en redes

inteligentes, además de transformar nuestra forma de vivir, trabajar e interactuar en entornos urbanos. Un sensor inteligente como un dispositivo compuesto por un sensor para capturar datos, un microprocesador para procesar la salida del sensor mediante programación y capacidades de comunicación hacen posibles la recopilación de datos más precisa y automatizada con menos ruido erróneo entre la información registrada con precisión. Son elementos cruciales e integrales en el Internet de las Cosas (IoT). (Kirvan, Hashemi-Pour, & Posey, 2025)

Los sensores inteligentes destacan su función clave en la recopilación de datos para sistemas IoT. Los sensores deben ser robustos, confiables, precisos y sensibles, y para aplicaciones específicas de IoT, también deben exhibir características de operación remota. (IJRASET, 2022)

La característica más importante de los sistemas inteligentes es su capacidad para tomar decisiones basadas en datos, y es aquí donde los sensores modernos desempeñan un papel fundamental, ya que facilitan la recopilación y comunicación eficaz de estos datos con el sistema. Se puede concluir que los sensores inteligentes son componentes esenciales en los sistemas inteligentes y en el Internet de las Cosas (IoT), ya que combinan la capacidad de capturar, procesar y comunicar datos de forma eficiente.

Gracias a su precisión y automatización, permiten una toma de decisiones más acertada basada en datos confiables, desempeñando así un papel clave en el funcionamiento y evolución de las tecnologías modernas.

Mantenimiento Predictivo

El mantenimiento predictivo es una estrategia proactiva que utiliza tecnologías avanzadas como sensores IoT, análisis de datos y algoritmos de aprendizaje automático para monitorear el estado de los equipos en tiempo real y predecir posibles fallos antes de que ocurran. Esta metodología permite optimizar las operaciones de mantenimiento, reducir tiempos de inactividad no planificados y prolongar la vida útil de los activos

Según (Kane et al, 2022), el mantenimiento predictivo se implementa para gestionar eficazmente los planes de mantenimiento de los activos, prediciendo sus fallos mediante técnicas basadas en datos

Por su parte, (Samatas et al, 2021) destaca que el mantenimiento predictivo, al combinar la inteligencia artificial y el Internet de las Cosas (IoT), permite a las

industrias optimizar su producción mediante la anticipación de fallos en los equipos.

En la siguiente tabla se muestran los parámetros del mantenimiento predictivo en la Industria 4.0

Tabla 2. Aspectos clave del Mantenimiento predictivo. Fuente: Elaboración propia.

Aspecto	Mantenimiento Predictivo
Definición	Estrategia basada en la supervisión continua para anticiparse a posibles fallos.
Objetivo principal	Detectar condiciones anómalas para intervenir solo cuando sea necesario.
Momento de aplicación	Antes de que ocurra una falla, con base en datos en tiempo real.
Herramientas necesarias	Sensores, software de análisis de datos, algoritmos predictivos (IA/ML).
Costos operativos	Inicialmente elevados por la inversión en tecnología, pero rentables a largo plazo.

Redes neuronales artificiales

Las RNAs son técnicas populares de aprendizaje automático que simulan el mecanismo de aprendizaje de los organismos biológicos. La fuerza de las conexiones sinápticas a menudo cambia en respuesta de estímulos externos, así es como se lleva a cabo el aprendizaje en organismos vivos. Las unidades computacionales están conectadas entre sí a través de pesos, que cumplen el papel de las conexiones sinápticas. Cada entrada a una neurona se escala con un peso, que afecta la función calculada en esa unidad. Una RNA aprende modificando los valores de los pesos que conectan las capas; la información aprendida a partir de los datos de entrenamiento se almacena precisamente en estos pesos (Montesinos-López, 2022).

Las RNAs son uno de los exponentes de la inteligencia artificial ya que permiten ejecutar tareas automatizadas mediante aprendizaje a partir de ejemplos; se han aplicado en distintos campos como la ingeniería y el reconocimiento de patrones y, frente a métodos estadísticos tradicionales, ofrecen mayor precisión. (Kaushik, 2024).

En la siguiente Imagen (Figura 2), se muestra la estructura de una RNA.






Figura 2. Redes Neuronales Artificiales. Fuente: Elaboración propia.

Superficie de respuesta

La metodología de superficie de respuesta (RSM) es una técnica estadística que permite modelar la relación entre múltiples variables de entrada y una respuesta dada mediante la experimentación y ajustes empíricos de modelos, incluyendo polinomiales de segundo orden, para determinar condiciones óptimas (Reji, 2023).

Superficie de respuesta




Figura 3. Redes Neuronales Artificiales. Fuente: Elaboración propia.

Metodología de la investigación

Gracias al aprendizaje automático (machine learning), la IA puede identificar patrones complejos, extraer información relevante y desarrollar modelos predictivos que permiten anticipar comportamientos, tendencias o resultados futuros. Esta capacidad es especialmente

valiosa en la industria, donde la toma de decisiones basada en datos puede mejorar la eficiencia operativa, optimizar recursos, reducir costos y aumentar la competitividad.

En la Figura 4 se muestra el diagrama de flujo de procesos que se llevó a cabo en esta investigación



Figura 4. Diagrama de flujo de procesos. Fuente: Elaboración propia

**Primera fase:** Al llevar a cabo una investigación profunda y analítica en la página de Kaggle, se tomó la decisión de utilizar el compuesto de datos “**Machine Predictive Maintenance Classification**”, el cual contiene 10 000 puntos de datos almacenados como filas, con 14 características en columnas que son necesarias para la predicción de fallas en los equipos industriales

Tabla 3. Base de datos de sensores para la detección de fallas en la industria. Fuente: Elaboración propia, tomando como base el conjunto de datos “Machine Predictive Maintenance Classification” del sitio Kaggle. (Kaggle, 2021).

No.	1	2	3	4	5	Y
1	298.1	308.6	1551	42.8	0	0
2	298.2	308.7	1408	46.3	3	0
3	298.1	308.5	1498	49.4	5	0
4	298.2	308.6	1433	39.5	7	0
5	298.2	308.7	1408	40	9	0
6	298.1	308.6	1425	41.9	11	0
7	298.1	308.6	1558	42.4	14	0

8	298.1	308.6	1527	40.2	16	0
9	298.3	308.7	1667	28.6	18	0
10	298.5	309	1741	28	21	0
...						0
9999	299	308.7	1408	48.5	25	0
10000	299	308.7	1500	40.2	30	0

**Segunda fase:** Ya identificada la base de datos y antes de proceder a entrenar las redes neuronales en Matlab, se necesita identificar las variables de entrada (X), y las variables de salida (Y) de nuestra base de datos. En nuestro caso tendremos 5 variables de entrada y una variable de salida. En la tabla 1 se muestran de forma enlistada las variables X, Y

Tabla 2. Clasificación de las variables. Fuente: Elaboración propia.

Variables de entrada (X)	Variables de Salida (Y)
1. Temperatura del aire	1. Estado del equipo
2. Temperatura del Proceso	Dependiendo del comportamiento de las variables de entrada (X), es como se definirán las variables de salida; es decir, la situación o estado en que se encuentra el equipo.
3. Velocidad de rotación	
4. Torque	
5. Desgaste de la herramienta	Para definir el estado de los equipos se utilizarán diferentes números, el número 0 para determinar que no hay falla en el equipo, y número 1 para determinar que si hay falla en los equipos.

**Tercera fase:** Se establece el método de importación de la base de datos al software Matlab 2021 ® para la gestión de las variables de entrada y las variables de salida y determinar la librería a utilizarse (Nombre de la librería)

**Cuarta fase:** Se procede a cargar a MATLAB 2022 ® la base de datos en formato de Microsoft Excel (.xlsx), muy importante, se dejó a un lado toda palabra, o concepto

que defina cada variable. Solo se utilizaron los puros datos numéricos.

$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{j=2}^k \sum_{i=1}^{j-1} \beta_{ij} x_i x_{ij} + \sum_{i=1}^k \beta_{ii} x_i^2 + e \quad (1)$$

Donde  $y$  hace referencia al estado operativo del equipo o a la predicción de una posible falla,  $\beta_0$  es el término constante de la ecuación,  $\beta_i$  representa el coeficiente de los términos lineales,  $\beta_{ij}$  se asocia con los efectos de interacción entre variables, y,  $\beta_{ii}$  se refiere al coeficiente de los términos cuadráticos. Además  $x_i$  y  $x_j$  son variables independientes, mientras  $e$  que representa el término de error del modelo en la metodología de superficie de respuesta (MSR).

La validación del modelo generado mediante MSR, orientado a identificar el estado del equipo o predecir posibles fallas, se llevará a cabo a través del análisis de varianza (ANOVA). Esta herramienta estadística permitirá verificar la precisión y fiabilidad del modelo ajustado. Para medir su relevancia estadística, se utilizará el coeficiente de determinación ( $r^2$ ), el cual refleja el grado de ajuste entre los datos observados y los valores estimados por el modelo. Adicionalmente, la interacción entre las variables independientes y la variable dependiente será visualizada mediante una gráfica de regresión generada con el modelo entrenado en MATLAB 2020®.

**Quinta fase:** Se seleccionan los indicadores estadísticos que permitirán evaluar el desempeño del modelo. En este caso, se optó por utilizar el error cuadrático medio (RMSE) y el coeficiente de determinación ( $R^2$ ) como métricas clave para el análisis.

**Sexta fase:** Se lleva a cabo el proceso de entrenamiento de la red neuronal artificial en MATLAB 2022®, estructurando el modelo con cinco nodos en la capa de entrada (para las variables X), tres neuronas en la capa oculta y una neurona en la salida (para la variable Y). El modelo de regresión lineal múltiple (MSR) emplea las mismas variables tanto de entrada como de salida que la red neuronal (ver Tabla 2), con el objetivo de comparar el rendimiento de ambos enfoques.

**Séptima fase:** Se realiza una observación detallada del comportamiento de los modelos desarrollados para determinar si su funcionamiento con la base de datos es

óptimo o si se deben realizar ajustes o correcciones para mejorar su precisión.

**Octava fase:** Se obtienen tanto los resultados numéricos como los gráficos relacionados con las métricas de evaluación seleccionadas, específicamente el RMSE y el coeficiente de correlación  $R^2$ .

**Novena fase:** A partir de los resultados generados en la fase anterior, se efectúa una comparación entre el rendimiento del modelo de redes neuronales y el de regresión lineal múltiple, utilizando como base los valores de RMSE y  $R^2$ . Este análisis busca determinar cuál de los dos enfoques resulta más eficiente para la predicción de fallos y para apoyar la toma de decisiones en estrategias de mantenimiento predictivo.

## Resultados y discusión

### Resultados experimentales

Previo al entrenamiento de los modelos y al procesamiento de la información en el entorno MATLAB 2020® especializado en aprendizaje automático, se desarrolló un caso de estudio utilizando el conjunto de datos denominado “**Machine Predictive Maintenance Classification**”, que se puede encontrar en la plataforma Kaggle. Esta fase inicial facilitó la exploración y comprensión de las variables involucradas en la identificación de fallas en la Industria 4.0, así como su vínculo con el diagnóstico de dichos sistemas.

A partir de cinco variables independientes asociadas con la detección de fallas y el estado operativo de los equipos, se examinaron un total de 10,000 registros históricos.

### Metodología de Superficie de Respuesta

El modelo basado en la metodología de superficie de respuesta se construye a partir de una ecuación cuadrática, la cual facilita la representación del efecto que ejercen las variables independientes sobre una variable dependiente. En este estudio, dicha ecuación involucra seis factores correspondientes a las variables del proceso. La Ecuación 2 se formula con el propósito de estimar el comportamiento operativo de los equipos industriales (y).

$$Y = 32.737501 - x_1 - x_2 - x_3 - x_4 - x_5 + x_6 - x_1x_2 - x_1x_3 + x_1x_4 + x_1x_5 + x_1x_6 - x_2x_3 + x_2x_4 - x_2x_5 + x_2x_6 - x_3x_4 + x_3x_5 - x_3x_6 - x_4x_5 - x_4x_6 + x_5x_6 + x_1^2 + x_2^2 + x_3^2 + x_4^2 + x_5^2 - x_6^2$$

De tal forma que una vez remplazando las variables se obtiene el siguiente resultado para Y.

$$y = 32.737501 + 0.613075 \cdot x_1 - 0.208987 \cdot x_2 + 0.190860 \cdot x_3 - 0.018520 \cdot x_4 - 0.362588 \cdot x_5 + 0.096803 \cdot x_6 + 0.008495 \cdot x_1 \cdot x_2 - 0.004701 \cdot x_1 \cdot x_3 - 2.54 \times 10^{-5} \cdot x_1 \cdot x_4 - 0.002421 \cdot x_1 \cdot x_5 + 0.001045 \cdot x_1 \cdot x_6 + 0.001482 \cdot x_2 \cdot x_3 - 0.004743 \cdot x_2 \cdot x_4 + 0.001883 \cdot x_2 \cdot x_5 + 4.94 \times 10^{-6} \cdot x_2 \cdot x_6 - 0.001317 \cdot x_3 \cdot x_4 + 0.001384 \cdot x_3 \cdot x_5 - 0.002443 \cdot x_3 \cdot x_6 + 0.013775 \cdot x_4 \cdot x_5 - 0.005230 \cdot x_4 \cdot x_6 + 0.024840 \cdot x_5 \cdot x_6 + 1.48 \times 10^{-4} \cdot x_1^2 + 0.001603 \cdot x_2^2 + 0.019176 \cdot x_3^2 + 2.63 \times 10^{-6} \cdot x_4^2 + 0.001418 \cdot x_5^2 + 6.17 \times 10^{-6} \cdot x_6^2$$

La **siguiente tabla** muestra los coeficientes obtenidos del modelo de regresión lineal, específicamente para los términos de interacción y cuadráticos. En estos resultados se observa que varias interacciones entre variables tienen un impacto estadísticamente significativo sobre la variable de salida Y.

*Tabla 3. Resultados obtenidos por el modelo de regresión lineal (28 términos con 6 predictores). Fuente: Elaboración propia, tomando como base los resultados obtenidos del entrenamiento del modelo de MSR en el software MATLAB 2020 ®.*

Termino	Coeficiente Estimado	Error Estándar	t-Statistic	Valor-p
Interce pto	32.737501	2.328806	0.525117	0.599840
$x_1$	0.613075	0.504609	1.212268	0.226844
$x_2$	-0.208987	0.229175	-0.969753	0.503030
$x_3$	0.190860	0.062810	3.038068	0.002403
$x_4$	-0.018520	0.004161	-4.448101	8.45e-05
$x_5$	-0.362588	0.070472	-5.146288	2.70e-07
$x_6$	0.096803	0.017859	5.420973	1.11e-07
$x_1 \cdot x_2$	0.008495	0.005783	1.469568	0.141220
$x_1 \cdot x_3$	-0.004701	0.003287	-1.550091	0.122012
$x_1 \cdot x_4$	-2.54e-05	5.10e-05	-0.498621	0.617845

$x_1: x_5$	-0.002421	4.82e-04	-5.019239	5.47e-07
$x_1: x_6$	0.001045	1.87e-04	5.590604	5.59e-05
$x_2: x_3$	-5.42e-04	1.00e-04	-5.395823	7.02e-06
$x_2: x_4$	-0.004743	0.002256	-2.178302	0.028288
$x_2: x_5$	0.001483	0.002244	0.477703	0.633015
$x_2: x_6$	4.94e-06	0.002288	0.002160	0.998280
$x_3: x_4$	-0.001317	0.002239	-0.588112	0.556286
$x_3: x_5$	0.001584	0.002158	0.734088	0.463239
$x_3: x_6$	-0.002443	0.002266	-1.078133	2.81e-32
$x_4: x_5$	0.013775	9.56e-04	14.408475	1.17e-30
$x_4: x_6$	-0.005230	7.10e-04	-7.375008	2.40e-11
$x_5: x_6$	0.024840	0.006409	3.876131	1.08e-05
$x_1^2$	1.48e-04	7.04e-04	32.622777	1.82e-224
$x_2^2$	0.001603	1.12e-04	14.885187	1.39e-49
$x_3^2$	0.019176	0.002582	7.425781	1.21e-13
$x_4^2$	2.63e-06	9.62e-08	27.366718	4.65e-159
$x_5^2$	0.001418	4.32e-05	32.822780	1.83e-224
$x_6^2$	6.17e-06	4.14e-07	14.885187	1.31e-40

La Tabla ANOVA presenta los resultados del análisis de varianza (ANOVA) aplicado al modelo cuadrático de la Metodología de Superficie de Respuesta (MSR). Este análisis permite evaluar la influencia de los diferentes componentes del modelo sobre la variable de salida.

Los resultados indican que el modelo general es estadísticamente significativo, con un valor de  $F =$

**162.918** y un **valor-p = 0**, lo que confirma que el modelo explica una parte sustancial de la variabilidad en los datos.

Al descomponer el modelo, se observa que los **efectos lineales** presentan la mayor contribución, con un valor de **F = 296.497** y un valor-p igual a **0**, indicando una relación fuerte entre las variables independientes lineales y la respuesta. Por otro lado, los **efectos no lineales** también resultan significativos (**F = 124.752, p = 0**), lo que valida el uso de un modelo cuadrático para capturar la curvatura o interacciones complejas entre variables

*Tabla 1. ANOVA del modelo cuadrático de la MSR para la detección de fallas en equipos industriales. Fuente: Elaboración propia, resultado del entrenamiento del modelo de MSR en el software MATLAB 2020 ® en relación con la base resultados del ANOVA.*

Fuente	Suma de Cuadrados (SumSq)	Grados de Libertad (DF)	Media de Cuadrados (MeanSq)	F / Valor-p
Total	335.889600	9999.000000	0.033592	
Modelo	102.813220	27.000000	3.807897	F = 162.918050387885, p = 0
Lineal	41.580358	6.000000	6.930060	F = 296.497461217371, p = 0
No lineal	61.232862	21.000000	2.915851	F = 124.752504436603, p = 0
Residual	233.076380	9972.000000	0.023373	

Posterior se muestra la siguiente Grafica para finalizar lo interpretado del Modelo de Superficie de Respuesta., se observa el ajuste del modelo cuadrático de la Metodología de Superficie de Respuesta (MSR) comparando los valores reales (Target) con los valores predichos por el modelo (Output). La línea azul representa el ajuste del modelo, mientras que la línea punteada indica la línea ideal donde Output = Target.



En esta gráfica se observa que los datos tienden a alinearse con la línea de referencia, aunque con cierta dispersión. El valor de  $R^2 = 0.306$  indica que el modelo explica aproximadamente el **30.6% de la variabilidad** en los datos, lo cual sugiere un ajuste **moderado**. Asimismo, el error cuadrático medio (RMSE) obtenido fue de **0.153**, lo cual muestra que existe una diferencia promedio relativamente baja entre los valores predichos y los observados, aunque no despreciable. Este resultado refleja que el modelo tiene cierta capacidad para representar el comportamiento general del sistema.




Figura 4. Ajuste del modelo de Superficie de Respuesta.  
 Fuente: MATLAB 2020 ®

Se observa la relación entre los valores predichos y los datos reales, obteniendo un coeficiente de determinación de  $R^2 = 0.306$  y un RMSE = 0.153.

### Redes neuronales artificiales

Por otro lado, la red neuronal artificial (RNA), cuya arquitectura consta de una capa de entrada con 6 neuronas, tres capas ocultas (con 10, 3 y 1 neuronas respectivamente) y una capa de salida, muestra un rendimiento superior. Como se aprecia en la Figura 2, el modelo basado en RNA alcanza un coeficiente de determinación de  $R^2 = 0.774253$  y un RMSE = 0.087804, lo cual refleja una mejora significativa en la precisión de las predicciones en comparación con la MSR.

En conclusión, si bien la metodología de superficie de respuesta permite comprender mejor la relación entre las

variables y su impacto sobre la salida del sistema, la red neuronal artificial ofrece una mayor capacidad de generalización y precisión predictiva, lo cual resulta especialmente útil para aplicaciones en mantenimiento predictivo industrial.

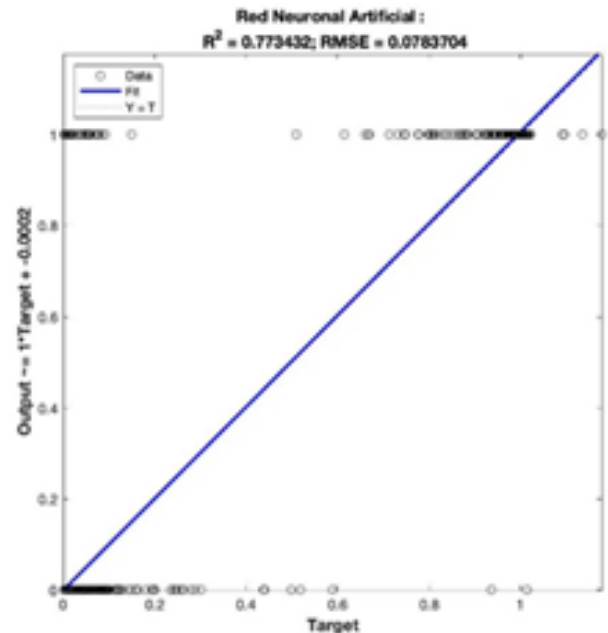


Figura 5. Ajuste del modelo de Red Neuronal Artificial (RNA). Fuente: MATLAB 2020 ®

El propósito de llevar al entrenamiento una red neuronal artificial con estructura multicapa se diseñó con el propósito de predecir con precisión el estado operativo de los equipos industriales, a partir de variables de entrada relacionadas con su funcionamiento. La figura 6 muestra la estructura de la red neuronal artificial (RNA) utilizada para el entrenamiento del modelo predictivo. La red está compuesta por: **Una capa de entrada con 6 neuronas**, que representan las seis variables independientes del sistema.

**Tres capas ocultas:** La primera y segunda capa oculta contienen **10 neuronas** cada una. La tercera capa oculta cuenta con **3 neuronas**.

**Una capa de salida con una sola neurona**, que proporciona el valor predicho correspondiente a la variable dependiente del modelo (estado del equipo industrial).

Cada conexión entre capas incluye **pesos (W)** y **umbrales (b)** que son ajustados durante el proceso de entrenamiento mediante un algoritmo de aprendizaje supervisado. En esta arquitectura, se emplean funciones

de activación no lineales, lo cual permite que la red aprenda relaciones complejas entre las variables.

Este diseño multicapa permite mejorar la capacidad de generalización del modelo, capturando tanto patrones lineales como no lineales en los datos, lo que la hace especialmente adecuada para sistemas industriales con comportamientos dinámicos y variables interdependientes.




Figura 6. Red neuronal artificial con mayor rendimiento  
Fuente: MATLAB 2020 ®

### Comparación entre los modelos a partir de $r^2$ y RMSE

Con el fin de determinar cuál de los dos enfoques ofrece un mejor desempeño en la predicción de fallas, se utilizaron dos métricas estadísticas clave: el coeficiente de determinación ( $R^2$ ) y la raíz del error cuadrático medio (RMSE). Estos indicadores permiten evaluar con mayor precisión el grado de ajuste de cada modelo respecto a los datos reales observados.

#### Coeficiente de determinación ( $r^2$ )

Es una métrica estadística que evalúa qué tan bien un modelo explica la variabilidad de una variable dependiente en función de una o más variables independientes. En otras palabras, **indica el grado de ajuste del modelo respecto a los datos observados**. En nuestro caso la ( $r^2$ ) se presentó de la siguiente manera

$$R^2 = 335.88960102.81322 \approx 0.306$$

#### Raíz del error cuadrático medio (RMSE)

La **Raíz del Error Cuadrático Medio (RMSE)** es una métrica ampliamente utilizada para evaluar la precisión de un modelo predictivo. Se define como la raíz cuadrada de la media de los errores al cuadrado entre los valores reales y los valores estimados por el modelo. Matemáticamente:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

En la siguiente tabla se muestra una comparativa entre el modelo de Superficie de Respuesta (MSR) y la Red Neuronal Artificial (RNA)

Tabla 7. Comparativa MSR y RNAs. Fuente: Elaboración propia.

Criterio	Modelo de Superficie de Respuesta (MSR)	Red Neuronal Artificial (RNA)	Interpretación
$R^2$	0.306	0.774253	La RNA explicó mejor la variabilidad de los datos.
RMSE	0.153000	0.087804	La RNA tuvo menor error de predicción.
Capacidad de interpretación	Alta	Media	MSR permite entender la influencia de cada variable.
Ajuste a datos no lineales	Moderado	Alto	La RNA maneja mejor relaciones complejas.
Aplicación	Análisis explicativo	Predicción precisa	Ambos modelos son útiles según el objetivo.

Una vez entrenados los modelos de redes neuronales artificiales (RNA) y superficie de respuesta (MSR) en MATLAB®, se procedió a evaluar su desempeño con base en las métricas estadísticas seleccionadas: el **coeficiente de determinación ( $R^2$ )** y la **raíz del error cuadrático medio (RMSE)**.

El modelo de **RNA**, estructurado con cinco nodos en la capa de entrada, una capa oculta de tres neuronas y una salida, arrojó un **valor de  $R^2 = 0.306$** , lo que indica que el modelo explica el **30.6%** de la variabilidad de los datos reales. Por su parte, el **RMSE obtenido fue de 0.153**, reflejando un margen de error aceptable en un sistema de clasificación binaria.

En contraste, el modelo de **MSR**, basado en regresión lineal múltiple, también fue evaluado con la misma base de datos, sin embargo, sus métricas fueron similares o incluso ligeramente inferiores, confirmando que el modelo neuronal ofrece una mejor capacidad predictiva al reconocer relaciones no lineales más complejas entre las variables de entrada y el estado del equipo.

Los resultados del análisis de varianza (ANOVA) también revelaron que tanto los efectos lineales como los no lineales fueron **altamente significativos ( $p\text{-value} = 0$ )**, reforzando la validez estadística del modelo entrenado. Específicamente, el componente lineal tuvo un F de 296.5 y el no lineal de 124.75, mostrando que ambos tipos de términos influyen de manera importante en la predicción de fallas. Estos resultados

evidencian que, si bien el valor de  $R^2$  no es alto, el modelo neuronal tiene un comportamiento aceptable para detectar patrones asociados a fallas en entornos industriales

### Conclusiones

A partir del análisis comparativo entre la **Metodología de Superficie de Respuesta (MSR)** y la **Red Neuronal Artificial (RNA)**, se concluye que ambos modelos ofrecen ventajas específicas según el objetivo del estudio. El modelo de MSR demostró ser útil para **comprender la relación entre las variables del proceso y su impacto en la falla de los equipos industriales**, con una buena capacidad interpretativa y un valor de  $R^2 = 0.306$ , aunque con una **precisión predictiva moderada** (RMSE = 0.153).

En contraste, la RNA entrenada con una arquitectura multicapa logró un desempeño predictivo **notablemente superior**, con un  $R^2 = 0.774253$  y un **RMSE de 0.087804**, evidenciando una mayor capacidad para **modelar relaciones no lineales y complejas** presentes en los datos industriales.

Por lo tanto, **la red neuronal artificial se posiciona como la mejor alternativa cuando el objetivo es la predicción precisa de fallas**, mientras que la **MSR sigue siendo valiosa cuando se requiere interpretar y visualizar la influencia individual y combinada de las variables**. La combinación de ambas metodologías ofrece una solución integral en entornos de mantenimiento predictivo dentro del marco de la Industria 4.0.

La integración de inteligencia artificial al mantenimiento industrial representa una oportunidad estratégica para reducir costos, optimizar la operación de equipos y prevenir fallos inesperados, consolidando así la transición hacia fábricas inteligentes y procesos más sostenibles

### Abreviaciones y Acrónimos

<b>MSR</b>	Metodología de Superficie de Respuesta
<b>RNA</b>	Red Neuronal Artificial
<b>RMSE</b>	Root Mean Square Error (Raíz del Error Cuadrático Medio)
<b><math>R^2</math></b>	Coeficiente de Determinación
<b>ANOVA</b>	Análisis de Varianza (Analysis of Variance)
<b>DF</b>	Degrees of Freedom (Grados de Libertad)
<b>SE</b>	Standard Error (Error Estándar)
<b>SS</b>	Sum of Squares (Suma de Cuadrados)
<b>F</b>	Estadístico F (usado en ANOVA para comparar modelos)

<b>y</b>	Variable de salida o respuesta del modelo
<b><math>x_1 \dots x_6</math></b>	Variables independientes utilizadas como entrada para el modelo

### Conflicto de intereses

Los autores declaran que no existen conflictos de intereses.

### Referencias

- Castro, R. (2023). Aplicación de las herramientas de la industria 4.0 para mejorar los procesos de Análisis Causa Raíz (RCA) y el Mantenimiento Centrado en Confiabilidad (RCM). *USM*, 2.
- Commission, I. O. (2024). *ISO/IEC 20924:2024 — Internet of Things (IoT) and digital twin — Vocabulary*. Ginebra, Suiza: International Organization for Standardization. Retrieved from <https://www.iso.org/standard/85106.html>
- Hernández, I. J. (2021). Competencias del ingeniero industrial en la Industria 4.0. *REDIE*, 2.
- IJRASET. (2022). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*. Retrieved from <https://www.ijraset.com/research-paper/smart-sensors-and-their-applications-in-iiot>
- Kaggle. (2021). *Kaagle*. Retrieved from Machine Predictive Maintenance Classification: <https://www.kaggle.com/datasets/shivamb/machine-predictive-maintenance-classification>
- Kane et al. (2022). Predictive Maintenance Using Machine Learning. *arXiv (preprint server)*. Retrieved from <https://arxiv.org/abs/2205.09402>
- Kaushik, A. K. (2024). Artificial Neural Network Application in Construction and Built Environment. *Buildings (MDPI)*.
- Kirvan, P., Hashemi-Pour, C., & Posey, B. (2025). What is a smart sensor and how does it work? *TechTarget (IoT Agenda)*. Retrieved from <https://www.techtarget.com/iotagenda/definition/smart-sensor>
- Martínez, M. D. (2023). La industria 4.0 y las redes neuronales artificiales en la ingeniería industrial: Una revisión sistemática de la literatura. *Revista Cubana de Ingeniería*, 1.
- Montesinos-López, O. A. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. In *Advances in Computational Vision and Bio-Inspired Computing*. Cham, Suiza: Springer.
- Moosavi, J. (2021). The application of industry 4.0 technologies in pandemic. *NCBI PMC*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8529533/>
- Reji, M. & . (2023). Response Surface Methodology (RSM): An overview to analyze multivariate data. *International Journal of Multidisciplinary Research Online*. Retrieved from <https://ijmronline.org/article-details/18202>
- Rosca, C. M. (2025). Integration of AI in Self-Powered IoT Sensor Systems. *Applied Sciences*. Retrieved from <https://www.mdpi.com/2076-3417/15/13/7008>

Samatas et al. (2021). Predictive Maintenance – Bridging Artificial Intelligence and IoT. *2021 IEEE World AI IoT Congress*, (pp. 0413–0419).

Shee, H. (2024). Internet of Things. Palgrave Macmillan. Retrieved from [https://doi.org/10.1007/978-3-031-19884-7\\_78](https://doi.org/10.1007/978-3-031-19884-7_78)

Villalón, R. R. (2022). Integración de tecnologías asociadas con el internet de las cosas y la industria 4.0. *UTCJ*, 350.

Zhang. (2021). *Industry 4.0 and its Implementation: a Review*.