Research Club Scientia Vol. 4, No 4
Frecuencia: Octubre–Diciembre 2026
ISSN: 3103 - 1315
DOI: https://doi.org/10.65415/f1fj1393

Modelado de la degradación y corrosión de los materiales en ambientes agresivos usando redes neuronales

Modeling the degradation and corrosion of materials in aggressive environments using neural networks

Modellazione del degrado e della corrosione dei materiali in ambienti aggressivi mediante reti neurali

Antonio Cesar Guevara Buenaño[I]
aguevarab6@unemi.edu.ec
ORCID: https://orcid.org/0009-0005-5194-8576
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Carlos Antonio Alvarado Guevara[I]
calvaradog2@unemi.edu.ec
ORCID: https://orcid.org/0009-0007-3332-7308
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Jean Carlos Zavala Lema[I]
jzavalal3@unemi.edu.ec
ORCID: https://orcid.org/0009-0002-3722-3606
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Jherel Segley Zuñiga Bohórquez[I]
jzunigab6@unemi.edu.ec
ORCID: https://orcid.org/0009-0008-4102-403X
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Jorge Tomas Holguín Anzules[I]
jholguina7@unemi.edu.ec
ORCID: https://orcid.org/0000-0003-4454-4184
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Correspondencia: calvaradog2@unemi.edu.ec

.

Modelado de la degradación y corrosión de los materiales en ambientes agresivos usando redes neuronales

Artículo de Investigación

Aceptado: 26/Noviembre/2026 **Publicado:** 27/Noviembre/2026

I. Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

.

Resumen

La corrosión y degradación de los materiales, porque son problemas que afectan a diferentes industrias, debido a que con el paso del tiempo pueden disminuir la resistencia, durabilidad y funcionamiento de los equipos. Estos daños se presentan principalmente cuando los materiales están expuestos a ambientes agresivos, como la humedad, el agua salada, las altas temperaturas o el contacto con sustancias químicas. Esta investigación tiene como objetivo conocer cómo las redes neuronales artificiales estudian y predicen el deterioro de los materiales en distintas condiciones ambientales. Para el desarrollo del trabajo, se revisaron artículos científicos, utilizando como fuente Scopus. En estos estudios se analizan diferentes procesos de corrosión y degradación, especialmente en materiales metálicos, así como los factores que pueden acelerar su desgaste. Entre ellos se encuentran la temperatura, la humedad, la concentración de sales y el tiempo que permanecen expuestos a determinadas condiciones. También se busca comprender cómo las redes neuronales trabajan con datos obtenidos de investigaciones y pruebas experimentales para identificar cambios en los materiales y realizar predicciones sobre su comportamiento. Con la información recopilada se pretende comparar los métodos utilizados por otros investigadores y conocer de qué manera estas herramientas pueden ayudar a estimar la vida útil de los materiales. Además, que es de importancia para detectar posibles daños con anticipación y facilitar la planificación del mantenimiento de máquinas, equipos y estructuras que se encuentran expuestos constantemente a condiciones que favorecen su deterioro. De esta manera, se espera conocer mejor la aplicación de estas tecnologías en el estudio de los materiales y su utilidad para prevenir problemas relacionados con la corrosión y degradación en diferentes industrias.

Palabras clave: Corrosión de materiales; Redes neuronales artificiales; Degradación de materiales; Ambientes agresivos.

Abstract

The corrosion and degradation of materials, as these are problems that affect different industries because, over time, they can reduce the strength, durability, and performance of equipment. This damage mainly occurs when materials are exposed to aggressive environments, such as humidity, salt water, high temperatures, or contact with chemical substances. This research aims to understand how artificial neural networks study and predict the deterioration of materials under different environmental conditions. For the development of this work, scientific articles were reviewed using Scopus as the source. These studies analyze different corrosion and degradation processes, especially in metallic materials, as well as the factors that can accelerate their deterioration. These factors include temperature, humidity, salt concentration, and the time materials remain exposed to certain conditions. The research also seeks to understand how neural networks work with data obtained from research and experimental tests to identify changes in

materials and make predictions about their behavior. With the information collected, the aim is to compare the methods used by other researchers and understand how these tools can help estimate the useful life of materials. In addition, the research seeks to understand their importance in detecting possible damage in advance and facilitating the planning of maintenance for machinery, equipment, and structures that are constantly exposed to conditions that favor their deterioration. In this way, the study is expected to provide a better understanding of the application of these technologies in materials research and their usefulness in preventing problems related to corrosion and degradation in different industries.

Keywords: Corrosion of materials; Artificial neural networks; Material degradation; Aggressive environments.

Riassunto

La corrosione e il degrado dei materiali, poiché si tratta di problemi che interessano diversi settori industriali, in quanto con il passare del tempo possono ridurre la resistenza, la durata e il funzionamento delle apparecchiature. Questi danni si verificano principalmente quando i materiali sono esposti ad ambienti aggressivi, come l'umidità, l'acqua salata, le alte temperature o il contatto con sostanze chimiche. Questa ricerca ha l'obiettivo di comprendere come le reti neurali artificiali analizzano e prevedono il deterioramento dei materiali in diverse condizioni ambientali. Per lo sviluppo del lavoro sono stati esaminati articoli scientifici, utilizzando Scopus come fonte. In questi studi vengono analizzati diversi processi di corrosione e degrado, soprattutto nei materiali metallici, così come i fattori che possono accelerarne l'usura. Tra questi si trovano la temperatura, l'umidità, la concentrazione di sali e il tempo di esposizione a determinate condizioni. Si cerca inoltre di comprendere come le reti neurali lavorano con i dati ottenuti da ricerche e prove sperimentali per identificare i cambiamenti nei materiali e formulare previsioni sul loro comportamento. Con le informazioni raccolte si intende confrontare i metodi utilizzati da altri ricercatori e comprendere in che modo questi strumenti possono aiutare a stimare la vita utile dei materiali. Inoltre, si cerca di comprendere la loro importanza per individuare in anticipo eventuali danni e facilitare la pianificazione della manutenzione di macchinari, apparecchiature e strutture costantemente esposti a condizioni che ne favoriscono il deterioramento. In questo modo, si spera di comprendere meglio l'applicazione di queste tecnologie nello studio dei materiali e la loro utilità nella prevenzione dei problemi legati alla corrosione e al degrado in diversi settori industriali.

Parole chiave: Corrosione dei materiali; Reti neurali artificiali; Degrado dei materiali; Ambienti aggressivi.

1. Introducción

Actualmente la degradación y corrosión son los principales problemas que afectan la resistencia, durabilidad y funcionamiento de nuestros materiales. Los cuales se encuentran en estructuras, máquinas, equipos y componentes metálicos. Esto se da debido a que están expuestos a condiciones ambientales agresivas, como la humedad, salinidad, altas temperaturas y el contacto con sustancias químicas, cuyas condiciones ambientales afectan de una forma acelerada al deterioro y la durabilidad del material.

La corrosión es considerada uno de los problemas más críticos en los procesos industriales, esta va de la mano de la degradación las cuales son las causantes del desgaste y reducción de durabilidad de un material especialmente en los materiales metálicos, es un proceso que puede ocasionar pérdida de espesor, debilitamiento estructural, aparición de grietas y daños que, en determinadas circunstancias, pueden provocar fallas en los equipos e instalaciones. Por esta razón, resulta importante estudiar el comportamiento de los materiales frente a diferentes condiciones ambientales, con el propósito de comprender los factores que influyen en su deterioro y encontrar alternativas que permitan prevenir o reducir sus efectos.

En los últimos 50 años, diversos estudios sobre corrosión han concluido que los costos de la corrosión pueden estimarse en un 3,4% del producto interno bruto (PIB) de cada nación. Según Iannuzzi y Frankel (2022), los costos directos asociados a la corrosión se estiman entre el 3 % y el 4 % del producto interno bruto (PIB) mundial. Estos costos están relacionados con la prevención, el control y el deterioro de los materiales. Sin embargo, existen otros gastos indirectos, como la pérdida de productividad, las interrupciones de los procesos industriales y las consecuencias ambientales ocasionadas por las fallas de los materiales

Estos costos estimados no consideran las consecuencias individuales para la seguridad o el medio ambiente, como incidentes, accidentes o interrupciones, entre otros. Varias industrias han demostrado que, mediante una gestión adecuada de la corrosión, se pueden lograr importante ahorro de costos.

Tradicionalmente, el análisis de la corrosión y la degradación se ha realizado mediante ensayos experimentales, inspecciones y modelos matemáticos que permiten evaluar el comportamiento de los materiales a lo largo del tiempo. Sin embargo, estos métodos pueden presentar limitaciones cuando intervienen numerosos factores ambientales y diferentes propiedades de los materiales. Ante esta situación, las nuevas tecnologías ofrecen herramientas que permiten mejorar el análisis y la predicción de estos fenómenos.

Una de estas herramientas es la inteligencia artificial, específicamente las redes neuronales artificiales, que son modelos computacionales capaces de aprender patrones y relaciones a partir

Research Club Scientia Vol. 4, No 4, Octubre - Diciembre, pp. 1744-1756, ISSN: 3103 – 1315

de grandes cantidades de datos. Mediante su aplicación, es posible analizar variables como la temperatura, la humedad, la concentración de sales, el tipo de material y el tiempo de exposición, con el objetivo de identificar su influencia en los procesos de corrosión y degradación. A partir de esta información, las redes neuronales pueden generar predicciones sobre el comportamiento futuro de los materiales bajo determinadas condiciones ambientales.

En este contexto, la presente investigación se centra en el modelado de la degradación y corrosión de materiales en ambientes agresivos usando redes neuronales, con la finalidad de estudiar cómo influyen las condiciones ambientales en el deterioro de los materiales y analizar la capacidad de los modelos de inteligencia artificial para predecir su comportamiento. De esta manera, se busca contribuir al desarrollo de herramientas computacionales que faciliten la evaluación de los materiales, permitan anticipar posibles daños y sirvan como apoyo para la planificación de actividades de inspección y mantenimiento en diferentes aplicaciones industriales.

2. Metodología

La presente investigación se desarrolla mediante un enfoque cualitativo, de tipo documental y bibliográfico, con el propósito de analizar el modelado de la degradación y corrosión de materiales expuestos a ambientes agresivos mediante el uso de redes neuronales artificiales (RNA). Para ello, se recopila información de diferentes artículos científicos que estudian el deterioro de materiales metálicos y la aplicación de herramientas de inteligencia artificial para analizar y predecir su comportamiento frente a distintas condiciones ambientales.

Para la búsqueda de información se consideran bases de datos académicas como Scopus, como herramienta de apoyo para localizar investigaciones relacionadas con el tema. Se toman como referencia publicaciones comprendidas entre los años 2020 y 2026, utilizando términos de búsqueda como corrosión de materiales, degradación, ambientes agresivos, redes neuronales artificiales, aprendizaje automático y predicción de corrosión, junto con sus equivalentes en inglés. La selección se orienta principalmente hacia estudios que presentan modelos predictivos relacionados con la corrosión, la oxidación y el deterioro de materiales utilizados en diferentes aplicaciones industriales. En los artículos seleccionados se analizan materiales metálicos.

También se estudian investigaciones relacionadas con tuberías metálicas, recubrimientos protectores y componentes expuestos a ambientes marinos. Estos materiales se encuentran sometidos a diferentes condiciones que pueden favorecer su deterioro, entre ellas la humedad, la temperatura, la presencia de cloruros, las sustancias químicas y los tiempos prolongados de exposición. Por ejemplo, Narayana et al. (2025) estudiaron la influencia de las condiciones atmosféricas en la corrosión del acero al carbono, mientras que Zhang et al. (2026) analizaron la corrosión por picaduras del acero inoxidable 316L en soluciones que contienen cloruros y cloratos. Posteriormente, se organiza la información mediante fichas bibliográficas que contienen los

Research Club Scientia Vol. 4, No 4, Octubre - Diciembre, pp. 1744-1756, ISSN: 3103 – 1315

autores, el año de publicación, los objetivos, los materiales estudiados, las técnicas utilizadas y los resultados más relevantes. Se identifican las variables que intervienen en los procesos de corrosión y degradación, así como los métodos empleados por los investigadores para obtener información experimental. Entre estas técnicas se encuentran la espectroscopia de impedancia electroquímica (EIS), la resistencia a la polarización lineal (LPR) y las mediciones del potencial de circuito abierto (OCP), utilizadas para estudiar el comportamiento de materiales metálicos frente a condiciones corrosivas. Asimismo, se examinan los diferentes modelos de redes neuronales utilizados en las investigaciones, entre ellos las redes neuronales de retropropagación (BPNN), las redes neuronales profundas (DNN), las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN). Se analiza cómo estos modelos permiten relacionar las propiedades de los materiales y las condiciones ambientales con los resultados experimentales. También se revisan los indicadores utilizados por los autores para evaluar el desempeño predictivo, como el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error cuadrático medio (MSE), cuando estos valores se encuentran disponibles en las publicaciones. Finalmente, se plantea un análisis comparativo de las investigaciones para identificar las semejanzas y diferencias entre los materiales, las condiciones de exposición, los modelos predictivos y los resultados obtenidos. Esta comparación busca reconocer qué factores presentan mayor influencia en los procesos de corrosión y degradación, además de examinar las ventajas y limitaciones de las redes neuronales artificiales. A partir de la información recopilada, se pretende comprender cómo estas herramientas pueden contribuir a la predicción del comportamiento de los materiales, la identificación temprana de daños y la planificación del mantenimiento en diferentes aplicaciones industriales.

Se revisan artículos en inglés y español publicados en la base de datos Scopus desde el año 2020, con el fin de conocer cómo ha avanzado el estudio de la corrosión y la degradación de los materiales a lo largo del tiempo y qué metodologías se han aplicado, entre ellas las redes neuronales artificiales, utilizadas para estimar la durabilidad, el tiempo de vida y el tiempo de mantenimiento de los materiales. Las palabras clave se combinan de manera que la búsqueda abarque el desgaste y la durabilidad de los materiales, el tiempo de mantenimiento, la degradación y la corrosión, estas dos últimas consideradas como las variables de estudio.

3. Resultados

Influencia de las condiciones ambientales en la corrosión y degradación

En la investigación realizada por Roy et al. (2023), se analizaron aleaciones FeCrAl sometidas a temperaturas de 1000 °C y 1200 °C durante dos horas. Los investigadores identificaron que la temperatura y las concentraciones de cromo y aluminio influyen en los cambios de masa del material durante la oxidación. Para realizar las predicciones se utilizaron los modelos Random Forest (RF) y modelado híbrido bayesiano (BHM).

Tabla I. Comparación del error de predicción en aleaciones FeCrAl.

Condición ambiental	Random Forest (NRMSE)	BHM (NRMSE)
Vapor	1,80	3,20
Aire	0,20	0,45
BWR-HWC	0,71	3,50
BWR-NWC	10,77	13,50
Conjunto general	1,13	2,26

A partir de la revisión de los artículos científicos, se identificó que la temperatura, la humedad, la concentración de sales y el tiempo de exposición son variables que intervienen en los procesos de corrosión y degradación de los materiales.

Narayana et al. (2025) identificaron que la humedad relativa fue el factor ambiental de mayor influencia en la velocidad de corrosión atmosférica del acero al carbono. Por otra parte, Zhang, C., et al. (2026) estudiaron la corrosión por picaduras del acero inoxidable 316L expuesto a soluciones de cloruro y clorato de sodio, utilizando redes neuronales para clasificar los diferentes niveles de deterioro.

En el caso de los materiales utilizados en la construcción, Zhang, P., et al. (2026) identificaron que la corrosión y las condiciones ambientales pueden afectar la adherencia entre el concreto geopolimérico y los materiales de refuerzo, disminuyendo la resistencia de la unión entre estos componentes.

Resultados de la aplicación de redes neuronales artificiales

Los estudios revisados muestran que las redes neuronales artificiales permiten relacionar las propiedades de los materiales y las condiciones ambientales con los datos obtenidos mediante pruebas experimentales.

Narayana et al. (2025) desarrollaron un modelo para predecir la corrosión atmosférica del acero al carbono, obteniendo un coeficiente de determinación (R^2) de 0,972 durante el entrenamiento y de 0,776 durante las pruebas.

Li et al. (2024) estudiaron la resistencia a la oxidación de aleaciones de níquel a altas temperaturas. La red neuronal de retropropagación utilizada obtuvo un coeficiente de determinación de 0,908, permitiendo analizar la influencia de la temperatura, el tiempo de exposición y la composición del material.

Research Club Scientia Vol. 4, No 4, Octubre - Diciembre, pp. 1744-1756, ISSN: 3103 – 1315

Asimismo, Kurtz et al. (2024) aplicaron una red neuronal profunda para identificar el estado de degradación superficial de una aleación de titanio Ti-6Al-4V. El modelo alcanzó una exactitud del 96 % en la clasificación de los espectros de prueba.

Ariffin et al. (2024) estudiaron la aplicación de un inhibidor de corrosión en acero dulce expuesto al agua de mar. Los resultados experimentales mostraron una eficiencia de inhibición del 83 % utilizando una concentración de 950 ppm a temperatura ambiente. En cuanto al modelo neuronal, el algoritmo Levenberg–Marquardt obtuvo un coeficiente de regresión de 0,907 y un error cuadrático medio de 0,006.

Por otra parte, Chen et al. (2025) abordaron el estudio de la resistencia a la corrosión del acero utilizado en rodamientos de robots marinos mediante un tratamiento superficial ultrasónico y la construcción de un modelo de red neuronal de retropropagación. Sin embargo, la información disponible no permitió identificar los valores de precisión obtenidos por el modelo.

Comparación de los resultados obtenidos

Tabla II. Resultados de modelos predictivos aplicados a la corrosión y degradación de materiales.

Investigadores	Material estudiado	Modelo	Resultado obtenido
Narayana et al. (2025)	Acero al carbono	ANN	R^2 = 0,776 en prueba
Li et al. (2024)	Aleaciones de níquel	BPNN	R^2 = 0,908
Kurtz et al. (2024)	Aleación Ti-6Al-4V	DNN	Exactitud del 96 %
Ariffin et al. (2024)	Acero dulce	ANN	R = 0,907; MSE = 0,006
Zhang, C., et al. (2026)	Acero inoxidable 316L	FFNN	Clasificación de la severidad de las picaduras
Xu et al. (2020)	Superficies metálicas	Faster R-CNN	Identificación de zonas afectadas por corrosión
Hu et al. (2026)	Tuberías de acero	WGAN-BNN-LSTM	Predicción de la evolución de la corrosión y vida útil remanente

Research Club Scientia Vol. 4, No 4, Octubre - Diciembre, pp. 1744-1756, ISSN: 3103 – 1315

Aplicación de los resultados en el mantenimiento industrial

Hu et al. (2026) desarrollaron una metodología que combina modelos de aprendizaje profundo y procesos estocásticos para estudiar la evolución de la corrosión en tuberías enterradas. Esta investigación permite identificar una posible aplicación de las redes neuronales en la estimación de la vida útil restante de los materiales.

Narayanan et al. (2024) combinaron mediciones electroquímicas con redes neuronales recurrentes para estudiar el comportamiento de barras de acero utilizadas como refuerzo durante periodos prolongados de exposición. Esta metodología puede proporcionar información de utilidad para conocer cómo evoluciona el deterioro de los materiales.

Asimismo, Xu et al. (2020) utilizaron redes neuronales convolucionales para detectar zonas afectadas por corrosión en superficies metálicas mediante el análisis de imágenes. Su aplicación puede contribuir a mejorar los procesos de inspección de equipos y estructuras industriales.

Como aporte metodológico complementario, Yang et al. (2024) estudiaron la identificación de los niveles de sobrecalentamiento durante la electrólisis del aluminio mediante redes neuronales convolucionales que incorporan conocimientos físicos del proceso. Aunque esta investigación no analiza directamente la corrosión, permite reconocer la importancia de integrar las condiciones físicas de los procesos industriales en los modelos computacionales.

En conjunto, los estudios revisados muestran diferentes aplicaciones de las redes neuronales, desde la identificación de daños superficiales hasta la predicción del deterioro y la estimación de la vida útil de los materiales.

Coelho et al. (2022) realizaron una revisión de 19 artículos científicos que comprendían 34 aplicaciones de aprendizaje automático relacionadas con la predicción de la corrosión. Los resultados mostraron una tendencia hacia la disminución del error de predicción al aumentar la cantidad de datos disponibles. También se identificó que incorporar el tiempo de exposición como variable de entrada favoreció el desempeño de los modelos, especialmente de las redes neuronales artificiales. Estos resultados se presentan en las figuras 3 y 4 del artículo.

Por otra parte, Jung y Kim (2025) analizaron el comportamiento de los aceros inoxidables 316L, 904L y AL-6XN, sometidos a diferentes condiciones ambientales. La red neuronal artificial utilizada para predecir las curvas de polarización alcanzó un coeficiente de determinación de 0,972, lo que permitió estimar características electroquímicas relacionadas con la corrosión de los materiales.

Variables experimentales

Tabla III. Variables utilizadas en el modelado de la corrosión de aceros inoxidables.

Variable	Nivel bajo	Nivel medio	Nivel alto
Temperatura (°C)	30	60	90
Concentración de cloruros (g/L)	20	30	40
pH	2	4	6
PREN	24	34	45

Estas variables fueron utilizadas en un diseño factorial de 81 combinaciones experimentales, con ensayos realizados por duplicado.

4. Discusión

Los resultados obtenidos a partir de la revisión de los artículos científicos permiten comprender que la corrosión y degradación de los materiales están relacionadas con diferentes factores, como la temperatura, la humedad, la concentración de sales, la composición química y el tiempo de exposición. Sin embargo, estas variables no influyen de la misma manera en todos los materiales, debido a que cada uno presenta diferentes propiedades y comportamientos frente a los ambientes agresivos.

Al comparar las investigaciones de Narayana et al. (2025), Li et al. (2024) y Kurtz et al. (2024), se observa que las redes neuronales artificiales pueden utilizarse para predecir la velocidad de corrosión, estudiar la resistencia a la oxidación e identificar daños superficiales. Aunque los modelos presentaron resultados favorables, no es posible establecer cuál tiene un mejor desempeño, debido a las diferencias entre los materiales estudiados, los datos experimentales y los indicadores utilizados para evaluar las predicciones.

Por otra parte, las investigaciones de Roy et al. (2023) y Li et al. (2024) coinciden en que la temperatura y la composición química tienen una influencia importante en la oxidación de las aleaciones metálicas. Roy et al. (2023) utilizaron los modelos Random Forest y modelado híbrido bayesiano para predecir los cambios de masa en aleaciones FeCrAl, obteniendo menores errores de predicción con Random Forest. Aunque estos modelos no corresponden directamente a redes neuronales artificiales, permiten ampliar la comparación entre las diferentes herramientas de aprendizaje automático utilizadas para estudiar el deterioro de los materiales.

Asimismo, Ariffin et al. (2024) y Chen et al. (2025) abordaron alternativas relacionadas con la protección de los materiales metálicos frente a la corrosión, mediante el estudio de inhibidores y

tratamientos superficiales. Estas investigaciones permiten reconocer que los modelos computacionales no solamente pueden utilizarse para predecir el deterioro, sino también para estudiar métodos que ayuden a reducir sus efectos.

En relación con el mantenimiento industrial, Hu et al. (2026), Kim et al. (2023) y Narayanan et al. (2024) estudiaron diferentes procesos de corrosión en tuberías y barras de acero. Por otra parte, Xu et al. (2020) utilizaron redes neuronales convolucionales para identificar zonas afectadas por corrosión mediante el análisis de imágenes. Estas aplicaciones pueden contribuir a detectar posibles daños con anticipación y facilitar la planificación de las actividades de inspección y mantenimiento.

Una de las principales limitaciones identificadas durante la revisión es la disponibilidad de datos experimentales. Roy et al. (2023) y Rojas-Valdivia et al. (2026) destacan la importancia de complementar los modelos computacionales con conocimientos sobre el comportamiento físico de los materiales. De manera similar, Yang et al. (2024), desde una aplicación relacionada con la electrólisis del aluminio, muestran la utilidad de incorporar conocimientos físicos en las redes neuronales cuando existe una cantidad limitada de información.

Desde el punto de vista de la Ingeniería Industrial, la aplicación de estas tecnologías puede contribuir a mejorar la selección de materiales, reducir los costos asociados al deterioro y facilitar la toma de decisiones relacionadas con el mantenimiento de máquinas, equipos y estructuras. No obstante, es necesario comprobar las predicciones mediante datos experimentales y condiciones reales de funcionamiento, debido a que los modelos pueden presentar limitaciones cuando se aplican a situaciones diferentes de aquellas utilizadas durante su entrenamiento.

Los resultados obtenidos por Jung y Kim (2025) permiten reconocer la importancia de relacionar la composición química de los materiales con las condiciones ambientales. En su investigación, el índice de resistencia a la corrosión por picaduras y la temperatura fueron los factores de mayor influencia en el comportamiento de los aceros inoxidables estudiados. La red neuronal artificial alcanzó un coeficiente de determinación de 0,972 en la predicción de las curvas de polarización, mostrando su capacidad para representar relaciones complejas entre las variables que intervienen en el proceso de corrosión.

Estos resultados se complementan con la investigación de Coelho et al. (2022), quienes identificaron que la cantidad de datos disponibles, el tiempo de exposición y la selección de las variables influyen en el desempeño de los modelos predictivos. Al relacionar estos aportes con las investigaciones de Narayana et al. (2025), Li et al. (2024) y Roy et al. (2023), se puede establecer que la confiabilidad de las predicciones no depende únicamente del modelo computacional seleccionado, sino también de la información utilizada durante su entrenamiento y de las características del material estudiado.

5. Conclusiones

La comparación de los artículos científicos permitió identificar que no existe un único modelo predictivo que pueda aplicarse de la misma manera a todos los materiales. La selección de una red neuronal o de otro modelo de aprendizaje automático debe realizarse de acuerdo con las propiedades del material, las condiciones ambientales y el tipo de deterioro que se desea analizar. Por lo tanto, obtener resultados favorables en una investigación no garantiza que el mismo modelo tenga un desempeño similar en otras condiciones.

Uno de los principales aportes de esta investigación fue reconocer la importancia de relacionar los conocimientos sobre el comportamiento físico y químico de los materiales con las herramientas computacionales. La disponibilidad de datos experimentales y la selección adecuada de las variables son aspectos fundamentales para obtener predicciones confiables. Por esta razón, las redes neuronales artificiales deben utilizarse como un complemento de los métodos experimentales y no como un reemplazo de estos.

En el ámbito de la Ingeniería Industrial, los conocimientos obtenidos mediante esta revisión pueden servir como base para futuras investigaciones orientadas al desarrollo de sistemas de monitoreo y mantenimiento predictivo. Sería conveniente estudiar la aplicación de estos modelos en condiciones reales de funcionamiento, incorporando información sobre los cambios que presentan los materiales durante periodos prolongados de exposición. Esto podría contribuir a prevenir fallas, reducir los costos de mantenimiento y aprovechar de mejor manera la vida útil de los equipos y estructuras industriales.

Agradecimientos

Agradezco al Msc. Jorge Tomás Holguín Anzules, docente de la Universidad Estatal de Milagro, por su guía, paciencia y valiosas observaciones durante el desarrollo de esta investigación.

Extiendo mi gratitud a la universidad, a mis compañeros y a todas las personas que, con su apoyo y colaboración, hicieron posible este trabajo

Referencias

Ariffin, A. H., Nik, W. M. N. W., Abdullah, S., Isa, M. I. N. M., Izionworu, V., & Zulkifli, M. F. R. (2024). Corrosion inhibition study of carboxymethyl cellulose-ionic liquid via electrochemical and machine learning technique. *Malaysian Journal of Analytical Sciences, 28*(2), 265–276.

Chen, T., Xia, D., Wang, S., Sun, X., & Zhang, J. (2025). Corrosion resistance of bearing steel for marine operating robots by ultrasonic surface rolling process and construction of BP neural

network prediction model. En *IEEE International Conference on Real-time Computing and Robotics (RCAR)* (pp. 986–991). https://doi.org/10.1109/RCAR65431.2025.11139617

Coelho, L. B., Zhang, D., Van Ingelgem, Y., Steckelmacher, D., Nowé, A., & Terryn, H. (2022). Reviewing machine learning of corrosion prediction in a data-oriented perspective. *npj Materials Degradation, 6*, Article 8. https://doi.org/10.1038/s41529-022-00218-4

Hu, Z., Cai, B., & Shao, X. (2026). Pipeline RUL prediction method that considers the coupling of multiple corrosion factors: Integrating deep learning and stochastic processes. *Reliability Engineering & System Safety, 267*, 111869. https://doi.org/10.1016/j.ress.2025.111869

Iannuzzi, M., & Frankel, G. S. (2022). The carbon footprint of steel corrosion. *npj Materials Degradation, 6*, Article 101. https://doi.org/10.1038/s41529-022-00318-1

Jung, K.-H., & Kim, S.-J. (2025). Statistical and ANN modeling of corrosion behavior of austenitic stainless steels in aqueous environments. *Materials, 18*(18), Article 4390. https://doi.org/10.3390/ma18184390

Kim, K., Kang, H., Kim, T., Iseley, D. T., Choi, J., & Koo, J. (2023). Influencing factors analysis for drinking water steel pipe pitting corrosion using artificial neural network. *Urban Water Journal, 20*(5), 550–563. https://doi.org/10.1080/1573062X.2023.2198996

Kurtz, M. A., Yang, R., Liu, D., Elapolu, M. S. R., Rai, R., & Gilbert, J. L. (2024). Deep neural network predicts Ti-6Al-4V dissolution state using near-field impedance spectra. *Advanced Functional Materials, 34*(4), Article 2308932. https://doi.org/10.1002/adfm.202308932

Li, C., Xu, K., Lou, M., Wang, L., & Chang, K. (2024). Machine learning-enabled prediction of high-temperature oxidation resistance for Ni-based alloys. *Corrosion Science, 234*, Article 112152. https://doi.org/10.1016/j.corsci.2024.112152

Narayana, P. L., Tiwari, S., Maurya, A. K., Ishtiaq, M., Park, N., & Reddy, N. G. S. (2025). Quantitative and qualitative analysis of atmospheric effects on carbon steel corrosion using an ANN model. *Metals, 15*(6), Article 607. https://doi.org/10.3390/met15060607

Narayanan, D., Lu, Y., Ponce, V., & Castaneda, H. (2024). Predicting long-term exposure performance of galvanized rebar based on artificial intelligence and electrochemical methods. *AMPP Annual Conference and Expo 2024*.

Rojas-Valdivia, L., Moraga, P., Peña, A., & García, J. (2026). Scientific machine learning for coating degradation and corrosion prediction: A critical review and thermodynamic

research perspective. *Coatings, 16*(8), Article 921. https://doi.org/10.3390/coatings16080921

Roy, I., Roychowdhury, S., Feng, B., Ravi, S. K., Ghosh, S., Umretiya, R., Rebak, R. B., Ruscitto, D. M., Gupta, V., & Hoffman, A. (2023). Data-driven predictive modeling of FeCrAl oxidation. *Materials Letters: X, 17*, Article 100183. https://doi.org/10.1016/j.mlblux.2023.100183

Xu, X., Wang, Y., Wu, J., & Wang, Y. (2020). Intelligent corrosion detection and rating based on faster region-based convolutional neural network. En *2020 Global Reliability and Prognostics and Health Management (PHM-Shanghai)*. https://doi.org/10.1109/PHM-Shanghai49105.2020.9281005

Yang, C., Wang, Z., Huang, K., & Gui, W. (2024). Physical-knowledge embedded convolutional neural network for aluminum electrolysis superheat degree identification. *IEEE Transactions on Industrial Electronics, 71*(8), 9698–9707. https://doi.org/10.1109/TIE.2023.3323745

Zhang, C., Yao, J., & Zhang, Z. (2026). Machine learning-based pitting rate classification and prediction for 316L stainless steel in $NaClO_3$ and NaCl environment. *Materials, 19*(10), Article 1979. https://doi.org/10.3390/ma19101979

Zhang, P., Zhang, N., Gao, J., & Gao, Z. (2026). Interfacial bonding behavior between geopolymer concrete and steel/FRP bars: A review. *Journal of Materials Science, 61*(38), 28513–28538. https://doi.org/10.1007/s10853-026-12919-1