Research Club Scientia Vol. 4, No 4
Frecuencia: Octubre–Diciembre 2026
ISSN: 3103 - 1315
DOI: https://doi.org/10.65415/hfvice91

Predicción del comportamiento tribológico y del desgaste en materiales avanzados mediante aprendizaje automático: una revisión sistemática

Prediction of Tribological Behavior and Wear in Advanced Materials Using Machine Learning: A Systematic Review

Previsione del comportamento tribologico e dell'usura nei materiali avanzati mediante apprendimento automatico: una revisione sistematica

Daniel Darío Alvarado Portilla[I]
dalvaradop12@unemi.edu.ec
ORCID: https://orcid.org/0009-0001-9440-5767
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Julio Cesar Arreaga Bautista[I]
jarreagab4@unemi.edu.ec
ORCID: https://orcid.org/0009-0003-8413-7652
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Ángel Jair Benavides Crespín[I]
abenavidesc3@unemi.edu.ec
ORCID: https://orcid.org/0009-0004-1126-4527
Facultad de Ciencias de la Ingeniería, Carrera Ingeniería Industrial, Universidad Estatal de Milagro, Ecuador

Jack Julian Castro Contreras[I]
jcastroc41@unemi.edu.ec
ORCID: https://orcid.org/0009-0009-4653-1476
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: dalvaradop12@unemi.edu.ec

Predicción del comportamiento tribológico y del desgaste en materiales avanzados mediante aprendizaje automático una revisión sistemática

Artículo de Investigación

Aceptado: 27/Noviembre/2026 **Publicado:** 28/Noviembre/2026

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

.

Resumen

El desgaste y la fricción condicionan la vida útil de componentes y herramientas, y su modelado físico es complejo. Esta revisión sistemática sobre un corpus cerrado de diez documentos (siete estudios incluidos, 2022–2025) sintetiza cómo el aprendizaje automático (ML) se emplea para predecir el comportamiento tribológico y el desgaste en materiales avanzados. Los estudios se agruparon en regresión supervisada sobre datos tabulares (n = 3), aprendizaje profundo sobre señales e imágenes (n = 2) y caracterización experimental sin ML (n = 2). Las redes neuronales fueron el enfoque dominante, con R^2 entre 0,69 y 0,99 y un RMSE de 0,0293 mm en la predicción del desgaste de herramienta; los modelos KNN y ELM perdieron precisión fuera del dominio de entrenamiento. Los vacíos principales son los conjuntos de datos pequeños, la validación externa escasa y las métricas no comparables. Los resultados orientan el uso del ML en ensayos de fricción y desgaste, aunque deben interpretarse con cautela por el tamaño del corpus.

Palabras clave: aprendizaje automático; desgaste; tribología; redes neuronales; revisión sistemática

Abstract

Wear and friction determine the service life of components and tools, and their physical modeling is complex. This systematic review of a closed corpus of ten documents (seven included studies, 2022–2025) synthesizes how machine learning (ML) is used to predict tribological behavior and wear in advanced materials. The studies were grouped into supervised regression on tabular data (n = 3), deep learning on signals and images (n = 2), and experimental characterization without ML (n = 2). Neural networks were the dominant approach, with R^2 between 0.69 and 0.99 and an RMSE of 0.0293 mm in tool wear prediction; KNN and ELM models lost accuracy outside the training domain. The main gaps are small datasets, scarce external validation, and non-comparable metrics. The findings guide the use of ML in friction and wear testing, although they should be interpreted with caution given the size of the corpus.

Keywords: machine learning; wear; tribology; neural networks; systematic review

1. Introducción

La tribología estudia la fricción, el desgaste y la lubricación de las superficies en contacto y en movimiento relativo. El conocimiento generado en esta disciplina ha contribuido a reducir los costos y las emisiones asociados a las máquinas; sin embargo, todavía se emplea cerca del 20 % de la energía mundial en vencer la fricción (Franco-Martínez et al., 2022; Holmberg y Erdemir, 2019). El desgaste, por su parte, es la pérdida progresiva de material de una superficie por su interacción con el entorno y suele originarse en el contacto entre asperezas bajo carga (Stachowiak,

2006). Obliga a decidir cuándo recuperar, recubrir o sustituir un componente en sectores como la generación de energía, la manufactura y el procesamiento de minerales (Cabanillas Flores, 2022).

Predecir la fricción y el desgaste es difícil porque intervienen muchos parámetros que interactúan entre sí, como la carga, la velocidad, la composición, la microestructura, la geometría y la lubricación. Por ello, gran parte de los trabajos publicados son experimentales y emplean equipos y condiciones de ensayo muy distintos, lo que dificulta comparar los resultados (Franco-Martínez et al., 2022). El problema se agrava en los materiales avanzados: el comportamiento tribológico de los aceros inoxidables hiperdúplex, de microestructura mixta, está escasamente estudiado (Del Sol Illana et al., 2025), y los recubrimientos de Zn-Al aplicados por spray térmico cuentan con muy pocos estudios tribológicos (Berlanga Labari et al., 2025).

El aprendizaje automático (ML, por sus siglas en inglés) ofrece una alternativa, porque aprende relaciones no lineales a partir de datos experimentales sin modelar los fenómenos físicos del contacto (Franco-Martínez et al., 2022; Muñoz-Valverde et al., 2024). La investigación sobre inteligencia artificial aplicada a la tribología creció de forma exponencial entre 1985 y 2020 (Marian y Tremmel, 2021). Se han predicho coeficientes de fricción lubricada con redes neuronales (Echávarri Otero et al., 2014) y con funciones de base radial, con un R^2 superior a 0,935 (Boidi et al., 2020). En el mecanizado, el ML se emplea para monitorizar el estado de la herramienta (Pimenov et al., 2022), aunque su adopción industrial se ve limitada por la escasez de datos etiquetados (Peralta Abadía et al., 2023).

Pese a este avance, la evidencia está dispersa entre familias de materiales, tipos de desgaste y algoritmos. El objetivo de este artículo es sintetizar, mediante una revisión sistemática de un corpus acotado, cómo se ha empleado el ML para predecir el comportamiento tribológico y el desgaste en materiales avanzados, qué datos y métricas se reportan y qué vacíos persisten. Tras la metodología, los resultados presentan la selección, la caracterización y la síntesis de los estudios; la discusión interpreta los hallazgos y sus límites, y las conclusiones resumen los aportes y las líneas futuras.

2. Metodología

Diseño y preguntas de investigación

Se realizó una revisión sistemática de la literatura sobre un corpus cerrado: diez documentos aportados por el equipo autor, de los que se extrajeron todos los datos y las referencias. No se ejecutaron búsquedas en bases de datos; por ello, la revisión no pretende ser exhaustiva y sus conclusiones se limitan al corpus analizado. El flujo de identificación, cribado, elegibilidad e inclusión se registró siguiendo la lógica del diagrama PRISMA (Figura 1). La revisión respondió cuatro preguntas: PI1, ¿qué algoritmos de ML se emplean para predecir fricción, desgaste o

deterioro superficial?; PI2, ¿qué datos y variables utilizan?; PI3, ¿qué desempeño y limitaciones reportan?; y PI4, ¿qué vacíos persisten?

Criterios de selección

Se incluyeron los documentos que (a) estudiaban la fricción, el desgaste, la dureza o el deterioro superficial de materiales, recubrimientos, componentes o herramientas; (b) reportaban un modelo de ML o datos de ensayos tribológicos que pudieran alimentarlo; y (c) estaban disponibles en texto completo, en español o en inglés. Se excluyeron los documentos duplicados y los trabajos sin relación con el desgaste, la fricción o el ML.

Extracción y síntesis de datos

Un revisor extrajo, con una ficha estandarizada, el país, el tipo de documento, el material, el método, el tamaño y la partición de los datos, las métricas y los resultados principales. La síntesis fue narrativa y se organizó por categorías. No se hizo metaanálisis porque las variables objetivo (gramos, milímetros, coeficiente de fricción, clases) y las métricas (MAE, MSE, RMSE, R^2 y tasa de error) no son comparables entre estudios. No se aplicó una escala formal de riesgo de sesgo; en su lugar, se registró si cada estudio informó la partición de los datos y si validó el modelo con datos independientes. Cuando el resumen de un documento discrepaba del cuerpo del texto, se priorizaron las tablas y los resultados detallados. Las cifras se transcribieron tal como las informan los autores.

3. Resultados

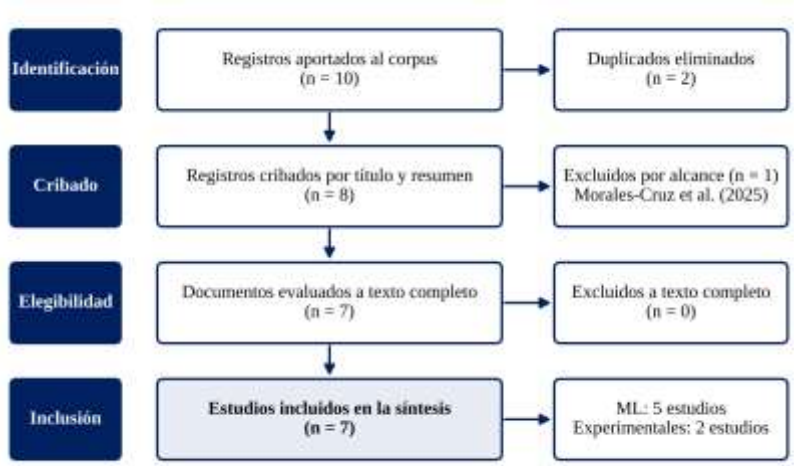
Selección de los estudios

El corpus inicial reunió 10 registros. Se eliminaron 2 duplicados (la tesis de Cabanillas Flores y el artículo de Valenzuela Cobos figuraban dos veces), por lo que se cribaron 8 documentos. En esa fase se excluyó uno (Morales-Cruz et al., 2025), que describe el diseño conceptual de un dispositivo accionado por cables para asistir el movimiento del hombro, el codo y la muñeca, y no analiza desgaste, fricción ni ML. Los 7 documentos restantes se evaluaron a texto completo y todos cumplieron los criterios, de modo que la muestra final fue de 7 estudios (Figura 1).

Research Club Scientia Vol. 4, No 4, Octubre - Diciembre, pp. 1845-1857, ISSN: 3103 – 1315

Figura 1

Flujo de identificación, cribado, elegibilidad e inclusión de los estudios



Nota. Elaboración propia, adaptada de la lógica del diagrama PRISMA.

Caracterización de los estudios incluidos

Los estudios se publicaron entre 2022 y 2025: dos en 2022, uno en 2023, dos en 2024 y dos en 2025. Cuatro provienen de España, dos de Ecuador y uno de Perú. Por tipo de documento, hay una tesis de pregrado, tres ponencias de congreso, dos artículos de revista y un artículo de investigación sin revista identificada. Los sistemas estudiados abarcan recargues duros base hierro, cobre microtexturizado, resinas fotopolimerizables, herramientas de fresado, superficies metálicas oxidadas, aceros hiperdúplex y recubrimientos de Zn y Zn15Al (Tabla 1). Cinco estudios aplicaron ML y dos fueron experimentales.

Tabla 1

Características de los estudios incluidos (n = 7)

Estudio	País y tipo	Sistema o material	Método	Datos
Cabanillas Flores (2022)	Perú; tesis	Recargues duros base hierro (ASTM G-65)	KNN, ANN y ELM; regresión de pérdida de masa	Registros AWS; 80 % / 20 %; contraste con ensayos PUCP

Estudio	País y tipo	Sistema o material	Método	Datos
Franco-Martínez et al. (2022)	España; ponencia (CIBIM)	Cobre microtexturizado; contacto bola-disco lubricado	KNN, árbol de decisión y red neuronal; regresión de fricción	21 probetas; 40 320 datos aumentados; 90 % / 10 %
Muñoz-Valverde et al. (2024)	Ecuador; artículo	Resinas Clear y Tough impresas por SLA	ANN 5-96-96-1; regresión de desgaste Taber y dureza	60 datos (diseño factorial); 80 % / 20 %
Peralta Abadía et al. (2023)	España; artículo	Herramienta de fresado (desgaste VB); NASA Ames/UC Berkeley	Robust-ResNet; regresión de VB	159 pasadas → 31 323 secuencias; 48 % / 12 % / 40 %
Valenzuela Cobos (2024)	Ecuador; artículo	Superficies metálicas oxidadas (imágenes)	ResNet-34 con y sin SVD; clasificación en 3 grados	240 imágenes; 70 % / 30 %
Del Sol Illana et al. (2025)	España; ponencia (CNIM)	Aceros hiperdúplex (HDSS) con y sin fase sigma	Pin-on-flat reciprocante; sin ML	5 cargas (1–30 N); 4 distancias (50–350 m)
Berlanga Labari et al. (2025)	España; ponencia (CNIM)	Recubrimientos Zn y Zn15Al sobre acero S235JR	Pin-on-disc y microscopía confocal; sin ML	3 espesores (50–200 µm); ensayos por duplicado

Nota. Elaboración propia a partir de los documentos revisados. ML = aprendizaje automático; AWS = American Welding Society; PUCP = Pontificia Universidad Católica del Perú; CIBIM = Congreso Iberoamericano de Ingeniería Mecánica; CNIM = Congreso Nacional de Ingeniería Mecánica.

Categorías temáticas

El análisis de contenido produjo tres categorías (Tabla 2).

Tabla 2

Categorías temáticas derivadas del análisis

Categoría	Descripción	Número de estudios	Estudios representativos
Regresión supervisada sobre datos tabulares de ensayos	Modelos KNN, árboles de decisión, ANN y ELM que estiman fricción, pérdida de masa, índice de desgaste o dureza a partir de composición, parámetros de proceso o geometría	3	Cabanillas Flores (2022); Franco-Martínez et al. (2022); Muñoz-Valverde et al. (2024)
Aprendizaje profundo sobre señales e imágenes	Redes residuales y convolucionales que estiman el desgaste de herramienta a partir de series temporales del CNC o clasifican el grado de oxidación a partir de imágenes	2	Peralta Abadía et al. (2023); Valenzuela Cobos (2024)
Caracterización experimental sin aprendizaje automático	Ensayos tribológicos que generan variables de entrada y de salida (carga, distancia, espesor, fricción, volumen de desgaste), pero no aplican modelos predictivos	2	Del Sol Illana et al. (2025); Berlanga Labari et al. (2025)

Síntesis de los hallazgos

En la regresión supervisada, Cabanillas Flores (2022) entrenó modelos KNN, ANN y ELM con registros de ensayos ASTM G-65 de la American Welding Society (AWS), con la composición

química y la dureza como entradas y la pérdida de masa como salida, y los contrastó con ensayos de la Pontificia Universidad Católica del Perú (PUCP). La ANN obtuvo el menor error en ambos bloques de datos (MAE de 0,228 g con datos de la AWS y de 0,086 g con datos de la PUCP), con una precisión del 85,75 % informada por el autor. El KNN convergió hacia el promedio de entrenamiento (1,60 g) al aumentar k, y la ELM sobreajustó los datos de entrenamiento, con un MAE de 0,853 g sobre los datos de la PUCP (Tabla 3).

Franco-Martínez et al. (2022) compararon KNN, árbol de decisión y red neuronal para predecir el coeficiente de fricción en contactos lubricados con superficies microtexturizadas. Los tres alcanzaron errores muy bajos (MSE de validación entre $6{,}48 \times 10^{-5}$ y $1{,}44 \times 10^{-4}$), pero KNN y árbol de decisión devolvieron valores discretos, casi insensibles a los cambios en la densidad del texturizado. Por ello eligieron la red neuronal, con la que exploraron 6 783 texturizados y seleccionaron tres geometrías que redujeron la fricción en 6 o 7 de 12 ensayos, aún sin verificación experimental. Muñoz-Valverde et al. (2024) predijeron con una ANN 5-96-96-1 el índice de desgaste Taber y la dureza de piezas impresas por estereolitografía, a partir del tipo de resina, el tiempo de curado y la orientación de impresión, con solo 60 datos. En validación, el R^2 fue de 0,75 y 0,69 para el desgaste de las resinas Clear y Tough, y de 0,92 y 0,97 para la dureza; el error porcentual fue mayor en el desgaste (cerca del 19 %) que en la dureza (entre 3,92 % y 6,87 %).

Tabla 3

Desempeño reportado por los estudios que aplican aprendizaje automático

Estudio	Modelo(s)	Variable objetivo	Métricas	Resultado principal
Cabanillas Flores (2022)	ANN; KNN (k = 6); ELM	Pérdida de masa (g)	MAE; RMSE	MAE (AWS / PUCP): ANN 0,228 g / 0,086 g; KNN 0,666 g / 0,726 g; ELM 0,321 g / 0,853 g
Franco-Martínez et al. (2022)	KNN; árbol de decisión; red neuronal	Coeficiente de fricción	MSE (validación)	KNN $6{,}61 \times 10^{-5}$; árbol $6{,}48 \times 10^{-5}$; red $1{,}44 \times 10^{-4}$ (elegida por su sensibilidad)
Muñoz-Valverde et al. (2024)	ANN 5-96-96-1	Desgaste Taber y dureza Shore D	MAE; MSE; R^2	R^2 del desgaste: 0,75 (Clear) y 0,69 (Tough); R^2 de la dureza: 0,92 y 0,97

Estudio	Modelo(s)	Variable objetivo	Métricas	Resultado principal
Peralta Abadía et al. (2023)	ResNet; ResNet-MA; ResNet-IP; ResNet-IP-MA	Desgaste de flanco VB (mm)	RMSE; R^2	ResNet-IP-MA: 0,0293 mm y R^2 0,9871; ResNet base: 0,1341 mm y R^2 0,7293
Valenzuela Cobos (2024)	ResNet-34 con y sin SVD	Grado de oxidación (3 clases)	Tasa de error; tiempo	1 error en 81 imágenes; tiempo 38–40 % menor; base de datos 70 % más liviana

Nota. Cifras tomadas del cuerpo y de las tablas de cada documento; cuando el resumen discrepaba, se priorizó el cuerpo. MAE = error absoluto medio; MSE = error cuadrático medio; RMSE = raíz del error cuadrático medio; R^2 = coeficiente de determinación; ANN = red neuronal artificial; KNN = k vecinos más cercanos; ELM = máquina de aprendizaje extremo; SVD = descomposición en valores singulares.

En el aprendizaje profundo, Peralta Abadía et al. (2023) estimaron el desgaste de flanco de la herramienta (VB) en fresado a partir de señales de corriente del husillo y de las condiciones de corte. La arquitectura con información de proceso y mecanismo de atención (ResNet-IP-MA) alcanzó un RMSE de 0,0293 mm y un R^2 de 0,9871, frente a 0,1341 mm y 0,7293 de la ResNet base; con solo la corriente continua, el RMSE subió a 0,0796 mm. Los autores informaron un margen de error medio del 9,7 %, cercano al 10 % del desgaste máximo que exige la industria. Valenzuela Cobos (2024) clasificó tres grados de oxidación en 240 imágenes con una ResNet-34; la descomposición en valores singulares redujo el tamaño de la base de datos un 70 % (de 2,18 GB a 670 MB) y el tiempo de entrenamiento entre 38 % y 40 %, y solo una de 81 imágenes de evaluadas se clasificó mal.

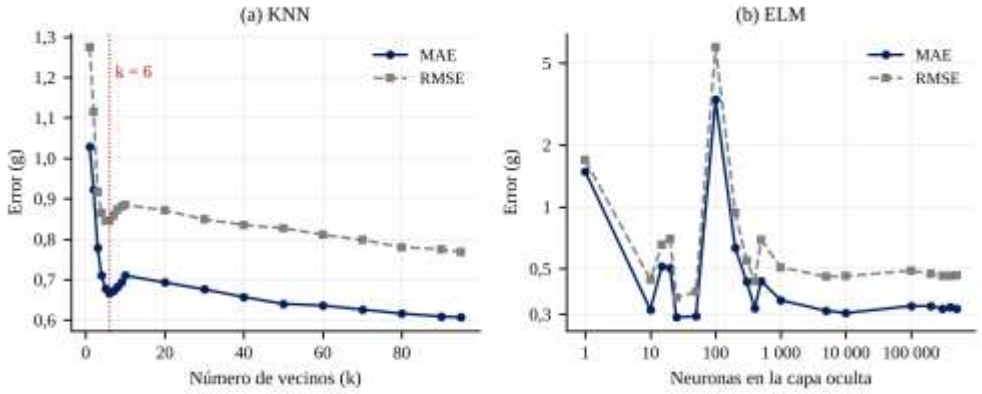
Los dos estudios experimentales aportan variables útiles para modelar. Del Sol Illana et al. (2025) hallaron que el coeficiente de fricción de dos aceros hiperdúplex disminuye al aumentar la carga de 1 a 30 N, mientras que el volumen de desgaste aumenta; además, la fase sigma elevó la microdureza un 72 % (de 327,67 HV a 563,33 HV) sin modificar la fricción. Berlanga Labari et al. (2025) observaron que los recubrimientos de Zn15Al presentaron coeficientes de fricción de 0,35 a 0,40, frente a 0,55 a 0,80 del Zn, y menor desgaste, sin que un mayor espesor mejorara el comportamiento.

Sensibilidad a los hiperparámetros

Solo Cabanillas Flores (2022) reportó de forma sistemática el efecto de los hiperparámetros (Figura 2). En el KNN, el menor MAE (0,666 g) se obtuvo con seis vecinos; con más vecinos, las predicciones se agrupan alrededor del promedio. En la ELM, el error no disminuyó de forma monótona al aumentar las neuronas: el MAE pasó de 0,290 g con 25 neuronas a 3,326 g con 100 y luego osciló entre 0,304 g y 0,632 g con 200 neuronas o más.

Figura 2

Efecto de los hiperparámetros sobre el error de predicción de la pérdida de masa



Nota. Elaboración propia con datos de las Tablas 6 y 8 de Cabanillas Flores (2022). Escala logarítmica en el panel (b).

Vacíos identificados

La revisión identificó cuatro vacíos. Primero, ningún estudio con ML modela la fricción o el volumen de desgaste de aceros inoxidables o de recubrimientos metálicos. Segundo, los conjuntos de datos son pequeños (60 datos en Muñoz-Valverde et al., 2024) o dependen de aumento de datos (Franco-Martínez et al., 2022; Peralta Abadía et al., 2023). Tercero, solo un estudio contrastó el modelo con ensayos de otro laboratorio (Cabanillas Flores, 2022). Cuarto, las métricas difieren entre estudios, lo que impide comparar el desempeño.

4. Discusión

Esta revisión buscó sintetizar cómo se aplica el ML para predecir el comportamiento tribológico y el desgaste en materiales avanzados. El hallazgo central es que las redes neuronales son el enfoque predominante y logran un ajuste alto dentro del dominio de datos con el que se entrenan, pero la evidencia sobre su capacidad de generalizar es limitada. Esto es relevante porque el valor práctico de estos modelos depende de que predigan materiales o condiciones no vistos.

El predominio de las ANN sobre datos tabulares puede explicarse porque capturan relaciones no lineales entre composición, parámetros de proceso y respuesta con poca ingeniería de variables (Muñoz-Valverde et al., 2024). El estudio de Franco-Martínez et al. (2022) muestra, además, que el MSE no basta como criterio de selección: el árbol de decisión tuvo el menor error de validación, pero produjo predicciones constantes ante cambios de densidad, de modo que resultó preferible un modelo con error ligeramente mayor y mayor sensibilidad. Algo similar ocurrió con el KNN de Cabanillas Flores (2022), cuyo error disminuyó al aumentar k mientras las predicciones colapsaban hacia el promedio, quizá porque los datos no forman una estructura ordenada que los vecinos locales puedan representar.

En el aprendizaje profundo, incorporar información de proceso y un mecanismo de atención redujo el RMSE de 0,1341 mm a 0,0293 mm (Peralta Abadía et al., 2023). Este resultado sugiere que la señal por sí sola no basta y que el contexto, en este caso las condiciones de corte, ayuda a interpretar el desgaste. Las arquitecturas residuales emplean conexiones de salto para mitigar el desvanecimiento del gradiente (He et al., 2016; Peralta Abadía et al., 2023), lo que facilita entrenar redes profundas. Sobre el mismo conjunto de datos, otros modelos habían reportado RMSE de 0,088 mm con una red convolucional (Aghazadeh et al., 2018) y de 0,0456 mm con una red LSTM híbrida (Cai et al., 2020), mientras que una máquina de aprendizaje extremo con núcleo alcanzó 0,003 mm al usar características manuales de tiempo y frecuencia (Zhou y Sun, 2020). Es decir, la ResNet logró un rendimiento comparable al estado del arte sin extraer características, aunque no superó al mejor modelo. Reducir la dimensionalidad de las imágenes puede recortar costos de cómputo sin degradar la clasificación (Valenzuela Cobos, 2024), pero ese resultado se apoya en una sola matriz de confusión con 81 imágenes.

Los hallazgos coinciden con la literatura previa en que el ML puede predecir variables tribológicas con buena precisión, como el R^2 superior a 0,935 con funciones de base radial (Boidi et al., 2020) o el de un árbol de decisión frente a otros modelos. A diferencia de esos trabajos, varios estudios revisados muestran límites claros: la ELM exigió elevados recursos computacionales por encima de 500 000 neuronas y sobreajustó (Cabanillas Flores, 2022). Además, las geometrías óptimas que predijo la red de Franco-Martínez et al. (2022) coinciden con la densidad de texturizado de 5 % a 10 % hallada experimentalmente, pero difieren en el tamaño, por lo que los propios autores advierten que debe comprobarse en el laboratorio. Los estudios experimentales revisados describen un comportamiento que un modelo predictivo debería capturar: la fricción baja con la carga mientras el desgaste sube, y la mayor dureza por fase sigma no reduce la fricción (Del Sol Illana et al., 2025), en línea con la alta influencia de esa fase informada por Rajkumar et al. (2019). Esto justifica el uso de modelos no lineales.

Desde una perspectiva práctica, los modelos revisados pueden apoyar la selección de recargues, de texturizados y del momento de cambio de herramienta, y reducir el costo de fabricar y ensayar

cada alternativa (Cabanillas Flores, 2022; Franco-Martínez et al., 2022; Peralta Abadía et al., 2023). En términos metodológicos, los estudios futuros deberían informar la partición de datos, validar con ensayos de otro laboratorio y usar métricas comunes. Existe, además, una oportunidad concreta: los ensayos de carga, distancia y espesor sobre aceros hiperdúplex y recubrimientos de zinc (Berlanga Labari et al., 2025; Del Sol Illana et al., 2025) aún no se han explotado con modelos predictivos.

La revisión tiene limitaciones. El corpus es cerrado y consta de diez documentos, sin búsqueda en bases de datos, por lo que no puede descartarse sesgo de selección. La selección y la extracción las hizo un solo revisor, no se aplicó una escala formal de riesgo de sesgo y tres de los siete estudios son ponencias de congreso y uno es una tesis. Algunos resúmenes contenían cifras que discrepaban del cuerpo del texto y se usaron las del cuerpo. Varias referencias de apoyo se citaron según lo que las fuentes revisadas informan de ellas. Estas limitaciones orientan una lectura prudente de los resultados.

5. Conclusiones

La evidencia revisada indica que el ML es viable para anticipar la fricción, el desgaste y el deterioro superficial cuando se dispone de datos de ensayo consistentes, y que la red neuronal es hoy la opción más utilizada. Sin embargo, la capacidad de generalizar no está demostrada en la mayoría de los estudios: solo uno validó el modelo con ensayos de otro laboratorio y los dos conjuntos de datos más grandes dependen del aumento sintético.

Para la práctica, esto significa que los modelos pueden orientar la selección de recargues, de texturizados o del momento de cambio de herramienta, pero sus predicciones deben verificarse experimentalmente antes de usarse en decisiones críticas. El aporte de esta revisión es ordenar un corpus heterogéneo en tres categorías y mostrar que los ensayos de fricción y desgaste en aceros y recubrimientos aún no se han explotado con modelos predictivos.

Referencias

Aghazadeh, F., Tahan, A., & Thomas, M. (2018). Tool condition monitoring using spectral subtraction and convolutional neural networks in milling process. *The International Journal of Advanced Manufacturing Technology, 98*, 3217–3227. https://doi.org/10.1007/s00170-018-2420-0

Berlanga Labari, C., Fernández Palacio, J., Claver Oliver, A., & Biezma Moraleda, M. V. (2025). Comparación de las propiedades tribológicas de recubrimientos de Zn y Zn-Al obtenidos por metalización. *Anales de Ingeniería Mecánica, 1*(24). https://doi.org/10.63450/aim.1.214.2025

Boidi, G., da Silva, M. R., Profito, F. J., & Machado, I. F. (2020). Using machine learning radial basis function (RBF) method for predicting lubricated friction on textured and porous surfaces. *Surface Topography: Metrology and Properties, 8*(4), 044002. https://doi.org/10.1088/2051-672X/abae13

Cabanillas Flores, R. (2022). *Desarrollo de modelo predictivo de desgaste basado en datos de ensayos según ASTM G-65 utilizando algoritmos de Machine Learning* [Tesis de pregrado, Pontificia Universidad Católica del Perú]. http://hdl.handle.net/20.500.12404/24085

Cai, W., Zhang, W., Hu, X., & Liu, Y. (2020). A hybrid information model based on long short-term memory network for tool condition monitoring. *Journal of Intelligent Manufacturing, 31*(6), 1497–1510. https://doi.org/10.1007/s10845-019-01526-4

Del Sol Illana, I., Vázquez Martínez, J. M., Niño, J., & Biezma-Moraleda, M. V. (2025). Efecto de la carga en el comportamiento tribológico de los aceros inoxidables hiperdúplex. *Anales de Ingeniería Mecánica, 1*(24). https://doi.org/10.63450/aim.1.139.2025

Echávarri Otero, J., de la Guerra Ochoa, E., Chacón Tanarro, E., Lafont Morgado, P., Díaz Lantada, A., Muñoz-Guijosa, J. M., & Muñoz Sanz, J. L. (2014). Artificial neural network approach to predict the lubricated friction coefficient. *Lubrication Science, 26*(3), 141–162. https://doi.org/10.1002/ls.1238

Franco-Martínez, F., García Moltó, J. J., Echávarri Otero, J., Chacón Tanarro, E., & Díaz-Lantada, A. (2022). *Aplicación de inteligencia artificial para la predicción de la fricción lubricada en contactos mecánicos microtexturizados* [Ponencia]. XV Congreso Iberoamericano de Ingeniería Mecánica, Madrid, España. https://doi.org/10.5944/bicim2022.106

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. En *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778). IEEE. https://doi.org/10.1109/CVPR.2016.90

Holmberg, K., & Erdemir, A. (2019). The impact of tribology on energy use and CO_2 emission globally and in combustion engine and electric cars. *Tribology International, 135*, 389–396. https://doi.org/10.1016/j.triboint.2019.03.024

Marian, M., & Tremmel, S. (2021). Current trends and applications of machine learning in tribology—A review. *Lubricants, 9*(9), 86. https://doi.org/10.3390/lubricants9090086

Muñoz-Valverde, P., Villena-López, O., Mayorga-Ases, L., Pérez-Salinas, C., & Moya, D. (2024). Prediction of abrasive wear and surface hardness of printed parts by SLA technology. *Ingenius*, (31), 19–31. https://doi.org/10.17163/ings.n31.2024.02

Peralta Abadía, J. J., Cuesta Zabaljauregui, M., & Larrinaga, F. (2023). *Monitorización de estado de la herramienta en mecanizado mediante redes neuronales residuales robustas* [Ponencia]. Congreso de Fabricación Avanzada y Máquinas-herramienta, Donostia-San Sebastián, España. https://hdl.handle.net/20.500.11984/6632

Stachowiak, G. W. (Ed.). (2006). *Wear: Materials, mechanisms and practice*. Wiley.

Valenzuela Cobos, A. G. (2024). Diseño de un modelo matemático para el análisis de imágenes en la identificación del grado de desgaste de superficies metálicas por efectos ambientales. *Ciencia y Educación*, 143–162. https://doi.org/10.5281/zenodo.12627290