

Gearbox Fault Diagnosis Based on Vibration Signal Processing and Machine Learning

Castro Diana, Ing¹ ; Melian Sara, MSc² ; Vera Simón, MSc³ .

^{1,3,2} Universidad Metropolitana Caracas, Caracas, Venezuela, diana.castro@correo.unimet.edu.ve, vvera@unimet.edu.ve, smelian@unimet.edu.ve

Abstract– Failures in industrial machinery represent a significant risk, as they can lead to production losses, reduced competitiveness, and accidents. Vibration measurement is the primary non-invasive method for detecting and predicting faults in rotating machinery components, since machines typically do not malfunction or fail without some warning, often indicated by an increase in vibration levels. However, the effectiveness of this method depends heavily on expert interpretation, limiting its automation and large-scale application. To overcome this limitation, this study proposes the development of a fault diagnosis model based on machine learning techniques applied to vibration signal analysis, aiming to diagnose the condition of a gearbox automatically and accurately. Data from the Open Energy Data Initiative (OEDI) repository for a wind turbine were utilized. The methodology included vibration signal preprocessing, feature extraction in the time and frequency domains, and the training of various classification models. Results indicate that the Support Vector Machine (SVM) model achieved the highest performance, with accuracy and precision values of approximately 98%, demonstrating the potential of machine learning to optimize predictive maintenance and early fault detection.

Keywords– Vibration Analysis, Gearbox, Fault Diagnosis, Machine Learning, SDG.

NOMENCLATURE

ML: Machine Learning
RMS: Root Mean Square
FC: Crest Factor
Exac: Accuracy
Pre: Precision
Rec: Recall

Modelo de diagnóstico de fallas de una caja de engranajes basado en señales de vibración y Machine Learning

Castro Diana, Ing¹ ; Melian Sara, MSc² ; Vera Simón, MSc³ .

^{1,3,2} Universidad Metropolitana, Caracas, Venezuela, diana.castro@correo.unimet.edu.ve, vvera@unimet.edu.ve, smelian@unimet.edu.ve

Resumen– Las fallas en la maquinaria industrial representan un riesgo significativo, ya que pueden ocasionar pérdidas de producción, reducir la competitividad y causar accidentes. La medición de vibraciones es el principal método no invasivo para la detección y predicción de fallas en los componentes de la maquinaria rotativa, dado que, por lo general, las máquinas no se averían o fallan sin algún tipo de advertencia, que se indica por un aumento en el nivel de vibración. Sin embargo, la efectividad de este método depende en gran medida de la interpretación experta, lo que limita su automatización y aplicación a gran escala. Para superar esta limitación, el presente estudio propone el desarrollo de un modelo de diagnóstico de fallas basado en técnicas de aprendizaje automático aplicado al análisis de señales de vibración, con el objetivo de diagnosticar el estado de una caja de engranajes de manera automática y precisa. Se utilizaron datos del repositorio Open Energy Data Initiative (OEDI) correspondientes a una turbina eólica, y la metodología incluyó el preprocesamiento de señales de vibración, la extracción de indicadores en los dominios de tiempo y frecuencia, y el entrenamiento de múltiples modelos de clasificación. Los resultados muestran que el modelo de Máquinas de Soporte Vectorial alcanzó el mejor desempeño, con valores de exactitud y precisión de aproximadamente 98%, evidenciando el potencial del aprendizaje automático para optimizar el mantenimiento predictivo y la detección temprana de fallas.

Palabras clave– Análisis de vibraciones, cajas de engranajes, diagnóstico de fallas, aprendizaje automático (ML), ODS.

NOMENCLATURA

ML: Machine Learning
RMS: Raíz media cuadrática
FC: Factor Cresta
Exac: Exactitud
Pre: Precisión
Rec: Recall

I. INTRODUCCIÓN

Las cajas de engranajes son componentes esenciales en sistemas mecánicos para la transmisión de potencia, por lo que su confiabilidad y rendimiento son cruciales en aplicaciones industriales. Las fallas en sus engranajes pueden tener serias consecuencias económicas y de seguridad. Por ello, es vital detectar las fallas en sus etapas iniciales para evitar paradas inesperadas, reparaciones costosas, daño operativo e incluso lesiones personales [1].

La condición de salud de una caja de engranajes puede reflejarse en diferentes mediciones, como datos vibratorios, eléctricos, térmicos, acústicos y basados en aceite [1]. Sin embargo, la técnica más empleada para determinar el estado de los componentes en los equipos y programar las actividades de

mantenimiento, sin afectar el tiempo de producción, es el análisis de vibraciones; esto es debido a que cualquier fallo en la caja de engranes se manifiesta como cambios en los patrones de vibración [2].

No obstante, para el uso adecuado de este método, se requiere un alto nivel de conocimiento y experiencia para interpretar efectivamente los resultados del análisis de vibraciones y, por consiguiente, personal capacitado [3].

Dadas las dificultades del análisis de vibraciones, se ha vuelto cada vez más popular la aplicación de la Inteligencia Artificial (IA) para el diagnóstico de máquinas [4]. De hecho, después del 2020 se reveló un marcado aumento en la actividad de investigación sobre el uso de métodos de Machine Learning (ML) en el análisis de vibraciones, principalmente en la detección de daños, la monitorización y el diagnóstico de sistemas [5].

Los modelos de aprendizaje tienen la capacidad de analizar grandes volúmenes de datos y ofrecer diagnósticos precisos en tiempo real. Ya que tienen la capacidad de identificar patrones complejos en los datos operativos y por lo tanto detectar anomalías tempranas [6]. Por lo que el uso de estas técnicas para el análisis de vibraciones permitiría establecer estrategias de mantenimiento basadas en el estado real de la maquinaria y no en intervalos de tiempo preestablecidos o en la reacción ante fallas [7], [8].

Asimismo, la automatización de estos procesos mediante el desarrollo tecnológico se alinea con las metas 9.5 y 9.b de los Objetivos de Desarrollo Sostenible (ODS), al fortalecer la investigación científica y la capacidad tecnológica industrial a través de la innovación.

A. Fundamentos teóricos

El fundamento teórico de esta investigación se basa en las técnicas de monitoreo de condición aplicado al análisis de vibraciones, partiendo del principio de que cada componente mecánico posee una firma vibratoria única cuya alteración indica procesos de degradación o fallas internas [9], [10].

Estas señales pueden analizarse en el dominio del tiempo, mediante la forma de onda e indicadores como RMS o factor de cresta, o en el dominio de la frecuencia, donde el espectro obtenido por la Transformada Rápida de Fourier permite identificar fallas específicas según cambios en amplitudes a frecuencias asociadas a cada componente [9], [11].

Ambos análisis permiten la extracción de múltiples indicadores de condición, los cuales pueden actuar como datos de entrada para modelos de aprendizaje automático

supervisado [12].

Investigaciones previas como la de Kafael et al. (2021) con un enfoque en la detección de fallas de un motor de inducción con técnicas de ML, destacan el uso de algoritmos de clasificación como las Máquinas de Soporte Vectorial (SVM), ya que superan las limitaciones de los métodos manuales y la necesidad de especialistas[8]. Este algoritmo, denominado clasificador lineal, busca encontrar el mejor separador (una línea, un plano o un hiperplano) que distinga óptimamente las clases de un conjunto de datos [12].

Otros trabajos más recientes como los de Zachariades y Xavier (2025) o Wilk-Jakubowski et al. (2025) enfocados en la detección de fallas de máquinas eléctricas, indican que para tareas de clasificación, los algoritmos de ML más comúnmente usados incluyen: los Árboles de Decisión, que facilitan la interpretación jerárquica de las variables; y Naive Bayes, que aporta eficiencia computacional basada en probabilidades [5], [13].

Teniendo en cuenta esta creciente demanda para la optimización del diagnóstico de máquinas y la indispensabilidad de las cajas de engranajes en diferentes sistemas mecánicos, esta investigación busca explorar el uso de técnicas de ML para el análisis estadístico de señales de vibración de una caja de engranajes.

La importancia de este trabajo radica en su potencial para optimizar los programas de mantenimiento, sirviendo como un caso ilustrativo de la implementación de modelos de ML para resolver problemas industriales críticos y favoreciendo la toma de decisiones en entornos industriales.

II. METODOLOGÍA

La metodología propuesta para el diagnóstico de fallas en la caja de engranajes se basa en la integración de técnicas de procesamiento de señales de vibración con modelos de aprendizaje automático supervisado. El procedimiento general se compone de cuatro etapas principales: adquisición de datos, preprocesamiento y extracción de características, selección de indicadores de condición, entrenamiento y validación de modelos de clasificación.

A. Adquisición de datos

La adquisición de datos se puede realizar utilizando diferentes tipos de transductores; el acelerómetro es uno de los tipos de sensores más comunes para adquirir la señal de vibración [14]. Los datos empleados de este estudio proceden del repositorio Open Energy Data Initiative (OEDI), desarrollado por el Laboratorio Nacional de Energías Renovables (NREL) de EE. UU. Este conjunto incluye mediciones reales de vibraciones obtenidas de un modelo de caja de engranajes de una turbina eólica de 750 kW, cuyo generador opera a 1800 rpm nominales. Está compuesta por tres etapas, tal como aparece en la Fig. 1: una planetaria de baja velocidad (LS) y dos etapas paralelas de velocidad intermedia (IMS) y alta (HS)[15].

Los datos recolectados pertenecen a dos cajas de engranajes de este modelo, una en buen estado y otra dañada. De esta base de datos fueron importadas un total de 160 señales de vibración de 8 acelerómetros ubicados en diferentes puntos del tren de transmisión; cada una contiene un minuto de datos muestreados a 40 kHz, e identificados en dos grupos de acuerdo a sus condiciones operativas: estado sano y estado dañado [15]. Esta base de datos permitió evaluar el desempeño del modelo de diagnóstico bajo condiciones reales de operación.




Fig. 1 Nomenclatura de la caja de engranajes. Fuente: Sheng (2014)

B. Procesamiento

El procesamiento de señales consiste en manipular, filtrar, digitalizar y analizar los datos en bruto para extraer información significativa. Esto permite la extracción de patrones e información de una gran cantidad de datos de vibración que, de otro modo, serían difíciles de interpretar [14].

El análisis se realizó en los dominios del tiempo y la frecuencia, aplicando técnicas como el Promediado Síncrono en el Tiempo (TSA), la Transformada de Hilbert (para el análisis envolvente), filtrado pasabanda y los espectros de potencia y órdenes; este proceso se ilustra en la Fig. 2. A partir de las señales procesadas se extrajeron múltiples indicadores de condición, incluyendo métricas estadísticas (RMS, curtosis, factor de cresta, asimetría, desviación estándar), indicadores de impulsividad y parámetros específicos del análisis TSA, como FM0, FM4, M6A y M8A.

C. Selección de Indicadores

Para garantizar que los modelos de aprendizaje automático se entrenaran con variables realmente representativas y evitar redundancias, se aplicaron las pruebas estadísticas ANOVA y Kruskal-Wallis a los indicadores de condición extraídos en la fase anterior. Estas pruebas permiten comparar varios grupos simultáneamente y determinar si existen diferencias significativas entre ellos, lo cual es adecuado para un modelo de clasificación multicategoría.

La aplicación conjunta de ANOVA y Kruskal-Wallis permitió garantizar que los indicadores seleccionados fueran significativos bajo distintos escenarios estadísticos, asegurando la validez de los resultados independientemente de la distribución de los datos




Fig. 2 Flujoograma de procesamiento de señales de vibración.

D. Entrenamiento

Se entrenaron tres modelos de clasificación: Árbol de Decisión, Máquina de Soporte Vectorial (SVM) y Naive Bayes. El conjunto de indicadores previamente seleccionados, fue dividido en datos de entrenamiento y prueba para evaluar su desempeño con información no vista. La evaluación se realizó mediante métricas como exactitud, precisión, recall y F1, primero a través de validación cruzada para obtener resultados preliminares y luego con el conjunto de prueba para analizar la capacidad de generalización y detectar sobreajuste.

Durante el proceso, los hiperparámetros fueron ajustados iterativamente para lograr un equilibrio entre precisión y robustez, y la comparación final de resultados permitió identificar el modelo más adecuado para el diagnóstico automático del estado de la caja de engranajes. El flujo general de este proceso se ilustra en la Fig. 3.

III. RESULTADOS Y DISCUSIÓN

Los modelos de clasificación propuestos fueron evaluados con el objetivo de analizar su capacidad para distinguir entre el estado normal y el estado dañado de la caja de engranajes en sus diferentes etapas. Para ello, cada medición del conjunto fue etiquetada considerando tanto la ubicación del sensor del cual se obtuvo la señal como el estado operativo, y fueron clasificadas en siete categorías, las cuales constituyen las clases de salida empleadas por los modelos de aprendizaje automático. La categoría "Normal" corresponde al funcionamiento adecuado de la caja de engranajes, mientras que las demás categorías representan la presencia de defectos en los componentes bajo su mismo nombre.

A partir de las etapas de entrenamiento y prueba de cada modelo se obtuvieron matrices de confusión que resumen su desempeño y su capacidad para diagnosticar correctamente la caja de engranajes. Con base en dichas matrices se calcularon

las métricas de evaluación de exactitud, precisión, sensibilidad (recall) y puntuación F1. En la Fig. 4 se presenta una de las matrices de confusión obtenidas durante el entrenamiento de uno de los modelos analizados.




Fig. 3 Flujoograma de entrenamiento de modelos.

A. ÁRBOLES DE DECISIÓN

Fueron entrenados tres modelos de árboles de decisión, modificando su máxima cantidad de nodos, de entre los tres modelos el árbol de decisión con más nodos (Árbol Fino) fue el que obtuvo mejores resultados con un porcentaje de exactitud en la validación cruzada de 98%. No obstante, al evaluarse con los datos de prueba, las métricas disminuyeron ligeramente a 95.24%, lo que indica una leve pérdida de generalización. Esto sugiere que, aunque los modelos lograron aprender adecuadamente los patrones principales de los datos

de entrenamiento, presentan una pequeña tendencia al sobreajuste. En la tabla I se muestran los resultados obtenidos de los modelos de árboles de decisión.

True Class	Fase Alta Velocidad	7						
	Fase Planetaria		14					
	Fase Velocidad Baja			7				
	Fase Velocidad Intermedia			2	5			
	Normal					49		
	Rodamiento delantero Alta Velocidad						7	
	Rodamiento trasero Alta Velocidad							7
		Predicted Class						
		Fase Alta Velocidad	Fase Planetaria	Fase Velocidad Baja	Fase Velocidad Intermedia	Normal	Rodamiento delantero Alta Velocidad	Rodamiento trasero Alta Velocidad

Fig. 4 Matriz de confusión obtenida del entrenamiento del modelo SVM Lineal.

B. MÁQUINAS DE SOPORTE VECTORIAL

Fueron entrenados seis modelos de SVM diferentes, variando su función de kernel en: kernel lineal, kernel cúbico, kernel cuadrático y kernel gaussiano. De entre los modelos entrenados, el SVM con un kernel gaussiano fue el que dio mejores resultados con un 100% de exactitud en la validación cruzada. Los modelos SVM fueron los que presentaron los mejores resultados de manera consistente. Los modelos Lineal, Cuadrático y Cúbico obtuvieron métricas prácticamente idénticas durante la validación y alcanzaron valores perfectos (100%) en todas las métricas durante la prueba. Esto demuestra una excelente capacidad de separación de clases y una fuerte generalización del modelo hacia datos no vistos. En la Tabla II se muestran los resultados del entrenamiento de todos los modelos de SVM.

C. NAIVE BAYES

Se entrenaron 2 modelos de Naive Bayes, uno empleando un clasificador Gaussiano y otro empleando kernel. Sin embargo, solamente el Naive Bayes Kernel obtuvo resultados en el entrenamiento, ya que el Naive Bayes Gaussiano falló debido a que la distribución de algunos predictores no se pueden acomodar en una distribución normal. El modelo Naive Bayes Kernel alcanzó un rendimiento notable, con una exactitud del 94.90% en validación y 97.62% en prueba. Al comparar los resultados de la validación y prueba, se puede apreciar una buena capacidad de generalización y una adaptación efectiva del modelo a los patrones de vibración no lineales, aunque su desempeño se mantiene ligeramente por debajo del observado en los modelos SVM. En la Tabla III se muestran los resultados obtenidos utilizando Naive Bayes.

D. Resultados generales

En términos globales, los modelos de SVM presentan los mejores resultados, con métricas consistentemente altas (incluso del 100%) tanto en validación como en prueba, lo que

indica una excelente capacidad de aprendizaje y generalización. Los árboles de decisión muestran buen desempeño en validación, pero una ligera caída en las métricas de prueba, lo que sugiere cierto grado de sobreajuste a los datos de entrenamiento. El modelo Naive Bayes Kernel se comporta correctamente, aunque con un rendimiento algo inferior a los SVM. Por otro lado, el SVM Gaussiano Fino y el Árbol Grueso muestran desempeños significativamente más bajos, evidenciando posibles limitaciones o configuraciones inadecuadas.

TABLA I
RESULTADOS DE ÁRBOLES DE DECISIÓN

Modelo	Validación				Prueba			
	Exac	Pre	Rec	F1	Exac	Pre	Rec	F1
Árbol Fino	97.96	97.96	95.92	95.92	95.24	95.24	90.48	90.34
Árbol Mediano	97.96	97.96	95.92	95.92	95.24	95.24	90.48	90.34
Árbol Grueso	80.61	80.61	61.22	61.83	83.33	83.33	66.67	57.48

TABLA II
RESULTADOS DE SVM

Modelo	Validación				Prueba			
	Exac	Pre	Rec	F1	Exac	Pre	Rec	F1
SVM Lineal	97.96	97.96	95.92	95.83	100	100	100	100
SVM Cuadrático	97.96	97.96	95.92	95.83	100	100	100	100
SVM Cúbico	97.96	97.96	95.92	95.83	100	100	100	100
SVM Gaussian Fino	58.16	58.16	22.45	20.46	57.14	57.14	21.43	19.52
SVM Gaussiano Medio	100	100	100	100	100	100	100	100
SVM Gaussian Grueso	85.71	85.71	71.43	71.77	100	100	100	100

Entre los modelos de SVM, las diferencias radican principalmente en la complejidad del hiperplano separador y la velocidad de procesamiento, más que en la precisión de clasificación. Por lo que para determinar el modelo más adecuado entre ellos, se compararon las métricas computacionales asociadas al rendimiento de los distintos modelos de clasificación, la Tabla IV muestra la comparación de velocidad de predicción, tiempo de entrenamiento y tamaño de modelo.

En términos generales, los modelos de árbol de decisión resultaron los más eficientes computacionalmente, alcanzando velocidades hasta un 97% superiores respecto al modelo más lento. En contraste, el Naive Bayes Kernel fue el modelo más pesado y lento, con un tamaño 95% mayor que el modelo más liviano y una velocidad de predicción 84% inferior al promedio general.

TABLA III
RESULTADOS DE NAIVE BAYES

Modelo	Validación				Prueba			
	Exac	Pre	Rec	F1	Exac	Pre	Rec	F1
Naive Bayes Kernel	94.90	94.90	89.80	90.72	97.62	97.62	95.24	95.10

TABLA IV
MÉTRICAS COMPUTACIONALES

Modelo	Velocidad de predicción (obs/seg)	Tiempo de entrenamiento (seg)
Árbol Fino	4860.27	11.54
Árbol Mediano	1904.03	6.81
Árbol Grueso	2783.43	7.30
Naive Bayes Gaussiano	-	10.14
Naive Bayes Kernel	77.66	24.25
SVM Lineal	208.95	20.48
SVM Cuadrático	1013.51	22.33
SVM Cúbico	936.22	12.89
SVM Gaussiano Fino	933.09	13.59
SVM Gaussiano Medio	403.12	14.38
SVM Gaussiano Grueso	883.87	11.11

Las SVM mostraron un buen equilibrio entre velocidad y tamaño, situándose alrededor de la media de velocidad de predicción (al menos un 4% más rápidas) y ocupando aproximadamente 40% menos espacio que el modelo de mayor tamaño. Entre ellas, destacaron las SVM Cuadrático y Cúbico, que combinaron buena velocidad (equivalente al 64% de la alcanzada por los árboles) con alta precisión total.

Por su parte, el SVM Gaussiano Medio, a pesar de presentar resultados de exactitud y precisión del 100%, fue el más lento entre los modelos SVM, con una velocidad 39% inferior a la media general del grupo de SVMs. En consecuencia, considerando simultáneamente los criterios de precisión y eficiencia computacional, el modelo SVM Cuadrático se identificó como el más equilibrado y eficiente dentro del conjunto evaluado.

IV. CONCLUSIONES

En resumen, de los resultados obtenidos podemos concluir que los árboles de decisión son los más eficientes en términos de velocidad y tamaño, los Naive Bayes, aunque precisos, resultan más demandantes en recursos, y los SVM ofrecen un buen balance entre desempeño y costo computacional, razón por la cual se destacan en el uso de diagnóstico y monitoreo de máquinas. La elección del modelo dependerá del compromiso requerido entre precisión y eficiencia en aplicaciones prácticas de diagnóstico o monitoreo en tiempo real.

Más allá del rendimiento algorítmico, esta investigación refuerza la relevancia del uso de técnicas de aprendizaje automático como herramientas efectivas y accesibles para el análisis de señales de vibración, evidenciando su capacidad

para procesar grandes volúmenes de datos con alta precisión y consistencia. El modelo propuesto no solo reduce significativamente la dependencia de la interpretación experta, sino que también mejora la rapidez y objetividad en la toma de decisiones, facilitando la implementación de estrategias de mantenimiento predictivo. En conjunto, estos hallazgos aportan una base sólida para futuras aplicaciones industriales, promoviendo sistemas de diagnóstico más inteligentes, automatizados y escalables.

REFERENCIAS

- [1] M. Azamfar, J. Singh, I. Bravo-Imaz, y J. Lee, "Multisensor data fusion for gearbox fault diagnosis using 2-D convolutional neural network and motor current signature analysis", *Mech. Syst. Signal Process.*, vol. 144, p. 106861, oct. 2020, doi: 10.1016/j.ymssp.2020.106861.
- [2] B. OLARTE C. WILLIAM BOTERO A. , MARCELA CAÑÓN A., "TÉCNICAS DE MANTENIMIENTO PREDICTIVO UTILIZADAS EN LA INDUSTRIA", *Sci. Tech.*, 2010, [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=84917249041>
- [3] A. Zavarce, "Rol de la Ingeniería Mecánica en el Análisis de Vibraciones", Inспенet. Consultado: el 22 de mayo de 2025. [En línea]. Disponible en: <https://inspenet.com/articulo/ingenieria-mecanica-analisis-de-vibraciones/>
- [4] M. H. Mohd Ghazali y W. Rahiman, "Vibration Analysis for Machine Monitoring and Diagnosis: A Systematic Review", *Shock Vib.*, vol. 2021, núm. 1, p. 9469318, 2021, doi: 10.1155/2021/9469318.
- [5] C. Zachariades y V. Xavier, "A Review of Artificial Intelligence Techniques in Fault Diagnosis of Electric Machines", *Sensors*, vol. 25, núm. 16, p. 5128, ago. 2025, doi: 10.3390/s25165128.
- [6] P. C. Moster, "Gear Fault Detection and Classification Using Learning Machines", *SOUND Vib.*, 2004.
- [7] F. A. G. Mora, J. L. Escobar Chávez, C. M. Gallegos Londoño, y E. S. Hernández Dávila, "El enfoque de aprendizaje conjunto en la detección de fallas en cajas de engranajes", *Rev. Univ. Soc.*, vol. 15, núm. 3, pp. 325–333, jun. 2023, Consultado: el 20 de septiembre de 2025. [En línea]. Disponible en: http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S2218-36202023000300325&lng=es&nrm=iso&tlng=es
- [8] A. Kafeel *et al.*, "An Expert System for Rotating Machine Fault Detection Using Vibration Signal Analysis", *Sensors*, vol. 21, núm. 22, p. 7587, ene. 2021, doi: 10.3390/s21227587.
- [9] S. S. Rao, D. S. García, R. R. Figueroa, y G. del V. D. Muñoz, *Vibraciones mecánicas*, vol. 776. Pearson educación, 2012.
- [10] T. Chu, T. Nguyen, H. Yoo, y J. Wang, "A review of vibration analysis and its applications", *Heliyon*, vol. 10, núm. 5, p. e26282, mar. 2024, doi: 10.1016/j.heliyon.2024.e26282.
- [11] G. White, "Introducción al análisis de vibraciones", *Woburn MA E. U. Ázima*, vol. 551, pp. 1990–2010, 2010.
- [12] A. Chehri, W.-B. Zounggrano, y A. Zimmermann, *Automatic classification of rotating machinery defects using machine learning (ml) algorithms*, vol. 189. Springer Nature, 2020.
- [13] J. L. Wilk-Jakubowski, L. Pawlik, D. Frej, y G. Wilk-Jakubowski, "The Evolution of Machine Learning in Vibration and Acoustics: A Decade of Innovation (2015–2024)", *Appl. Sci.*, vol. 15, núm. 12, p. 6549, ene. 2025, doi: 10.3390/app15126549.
- [14] M. Romassini, P. C. C. De Aguirre, L. Compassi-Severo, y A. G. Girardi, "A Review on Vibration Monitoring Techniques for Predictive Maintenance of Rotating Machinery", *Eng.*, vol. 4, núm. 3, pp. 1797–1817, jun. 2023, doi: 10.3390/eng4030102.
- [15] S. Sheng, "Wind Turbine Gearbox Condition Monitoring Vibration Analysis Benchmarking Datasets". DOE Open Energy Data Initiative (OEDI); National Renewable Energy Laboratory, p. 5 files, 2014. doi: 10.25984/1844194.