

Preprocesamiento de datos en el pronóstico de fallos de rodamientos para el mantenimiento predictivo

José Luis Molina Salgado, Máximo López Sánchez*, René Santaolaya Salgado,
Noé Alejandro Castro Sánchez

Tecnológico Nacional de México, Computación, Cuernavaca,
México

joseluis.molina@cenidet.edu.mx, {maximo.ls, rene.ss, noe.cs}@cenidet.tecnm.mx

Resumen. Este trabajo presenta un método de preprocesamiento de datos de vibración para la clasificación y predicción de fallos en rodamientos. Este método extiende el tiempo de previsión de fallos en comparación con trabajos anteriores, utilizando menos recursos computacionales. Actualmente, el mantenimiento industrial se realiza con el apoyo de sistemas computacionales, los cuales gestionan la información relacionada con el estado de salud de las máquinas. Las estrategias más utilizadas son el mantenimiento basado en la condición y el mantenimiento predictivo, los que se usan para maximizar la vida útil restante de una máquina o de un elemento de ella. La motivación para este trabajo surge de la observación de los procesos metodológicos utilizados para realizar el mantenimiento industrial, ya que se percibe que los procesos de procesamiento de datos requieren un conocimiento computacional significativo. Adicionalmente, estos procesos se llevan a cabo mediante técnicas que descuidan información importante como el origen o la manera en que se adquieren los datos. El método propuesto se utilizó para demostrar el comportamiento de diferentes algoritmos de clasificación como Máquinas de Vectores de Soporte, Bosques Aleatorios, Árboles de Decisión y algoritmos de regresión como la Regresión Lineal y Redes Neuronales sobre un conjunto de datos reales. Con esto, es posible realizar la previsión de fallos en rodamientos con más antelación, obteniendo una mejora del 74.4% en comparación con trabajos relacionados. Utilizar este método de preprocesamiento de datos para la creación de modelos de aprendizaje automático nos permite reducir la complejidad del proceso mientras disminuimos el número de procesos realizados. Esto representa una gran ventaja para la industria favoreciendo estrategias de mantenimiento.

Palabras clave. Mantenimiento 4.0, aprendizaje automático, preprocesamiento de datos, vida útil restante, previsión, rodamientos

Data Preprocessing in Bearing Failure Prognostics for Predictive Maintenance

Abstract. This work presents a method of vibration data preprocessing for the classification and prediction of bearing failures. This method extends the failure prediction forecast time compared to previous works, using fewer computational resources. Currently, industrial maintenance is carried out with the support of computational systems, which manage the information related to the health status of the machines. The most commonly used strategies are condition-based maintenance and predictive maintenance, which are used to maximize the remaining life of a machine or an element of it. The motivation for this work arises from the observation of the methodological processes used to perform industrial maintenance, as it is perceived that data processing processes require significant computational knowledge. Additionally, these processes are carried out through techniques that neglect important information such as the origin or the way the data is acquired. The proposed method was used to demonstrate the behavior of different classification algorithms such as Support Vector Machines, Random Forest, Decision Trees, and regression algorithms like Linear Regression and Neural Networks on a dataset of real data. With this, it is possible to make the forecast of bearing failures with more advance notice, obtaining an improvement of 74.4% compared to related works. Using this data preprocessing method for the creation of Machine Learning models allow us to reduce the complexity of the process while decreasing the number of processes performed. This represents a great advantage for the industry by favoring maintenance strategies.

Keywords. Maintenance 4.0, machine learning, data preprocessing, remaining useful life, forecast, bearings.

1. Introducción

Durante la evolución de la industria desde la primera revolución industrial hasta la actualidad, la forma en que se producen y mantienen los equipos mecánicos ha experimentado cambios constantes

En [1], se menciona que el costo por hora de mantenimiento se ha incrementado a pesar de que hay menos incidentes. Este reporte hace mención que el tiempo de inactividad no planificado a las Empresas Fortune les cuesta casi 1.5 billones de dólares, superando los 864,000 millones de dólares del año 2020.

Desglosando los costos por sector, según [1], el costo de una hora perdida oscila, en promedio, entre unos 39,000 dólares para las fábricas que producen bienes de consumo de rápido movimiento, hasta más de 2 millones de dólares por hora en el sector automotriz, por lo que, considerando el costo promedio por minuto de las primeras, éste tiene una media de los 650 dólares por minuto, mientras que las segundas su costo promedio por minuto es de 33,333.33 dólares por minuto. De ahí la importancia de tener un tiempo de predicción de las fallas de los equipos, para poder ajustar los procedimientos de mantenimiento sin generar una gran afectación.

En este artículo nos centraremos en una técnica fundamental en la gestión del mantenimiento predictivo en la industria moderna: el preprocesamiento de datos de diagnóstico de fallas en rodamientos. La evolución de la industria se ha dado en cuatro etapas conocidas como revoluciones industriales. La primera etapa se caracterizó por la introducción de herramientas y mecanización en los procesos manuales de producción. La segunda revolución se dio con la inclusión de la electricidad como fuente de energía y la aplicación de cadenas de producción.

Posteriormente, la tercera revolución industrial trajo consigo la automatización de sistemas y el uso de sistemas informáticos. Finalmente, la industria moderna se encuentra en la cuarta revolución industrial, donde se integran tecnologías como el Internet de las cosas (IoT), el cómputo en la nube (CC) y los sistemas ciberfísicos (CPS), entre otras.

El mantenimiento industrial es una parte clave en la gestión de una fábrica. Una correcta planificación se traduce en un mayor control de los

recursos, tanto humanos como materiales. En [2] se sugiere que los buenos planes de mantenimiento predictivo (PdM) pueden reducir los costos medios a lo largo del tiempo [2].

En la industria moderna, los sistemas computacionales son utilizados en una gran variedad de tareas, tales como la gestión del personal, la toma de decisiones, el manejo de recursos industriales, o cualquier tarea que requiera de un análisis computacional [3]. El PdM no es la excepción, ya que se apoya en herramientas como el Aprendizaje Automático (ML) para conocer el estado de salud o realizar la estimación de la vida útil restante (RUL) de una máquina.

En la industria 4.0, el monitoreo de las máquinas se lleva a cabo mediante diferentes tipos de sensores, tales como térmicos, fotovoltaicos, de humedad, de vibración o acústicos. Cada uno de ellos otorga señales que, posteriormente, a través de un procesamiento, pueden ser interpretadas como información representativa. Esta resulta de gran utilidad para realizar adecuados programas de mantenimiento predictivo, utilizando ML.

Existen diferentes tipos de mantenimiento que se pueden utilizar en la industria, sin embargo, para elegir uno de ellos, es necesario identificar las características de mantenimiento más adecuadas a las instalaciones y los equipos disponibles. Es posible diferenciar que el mantenimiento predictivo y el mantenimiento basado en condición son las técnicas que permiten extender la vida útil y minimizar los tiempos de inactividad en las instalaciones. No obstante, con estos tipos de mantenimiento es necesario contar con más información y realizar tareas de planificación más complejas.

Uno de los equipos de trabajo más utilizados en la industria son las máquinas rotativas, las cuales tienen en común el uso de rodamientos, cuya función es reducir el rozamiento que existe entre las partes en las que giran los ejes.

Estas piezas mecánicas son fundamentales, ya que de ello depende el correcto funcionamiento de estas máquinas. Los rodamientos requieren de una adecuada lubricación y mantenimiento, ya que con el deterioro comienzan a producir vibraciones no deseadas en los equipos mecánicos, lo que finalmente llega a causar fallas mayores [4].

Tabla 1. Análisis para el mantenimiento predictivo

Artículo	Sensores utilizados	Máquina o componente evaluado
[12]	-IMU -Térmicos -Acústicos	---
[15]	-IMU	-Banda transportadora
[18]	N/A	-Motor AC
[10]	-Acústicos -Térmicos	-Fresas -Rodamientos
[16]	-Fotoeléctricos	-Fresas -Rodamientos
[19]	-IMU	-Motor AC
[20]	-IMU	-Generador
[14]	-Térmicos -Humedad	-Motor AC -Condensador

Tabla 2. Algoritmos de machine learning

Algoritmos	Utilizado en los trabajos
Random Forest (RF)	[21], [24], [25], [28]
Logistic Regression (LoR)	[21]
Support Vector Machine (SVM)	[21], [23], [24], [27]
Gradient Boosted Tree (GBT)	[21]
Linear Regression (LR)	[24], [26], [27]
Neural Networks (NN)	[22], [23], [26], [28]
Fuzzy Logic (FL)	[22]
Bayesian Networks (BN)	[23]
DecisiónTree (DT)	[24]
K-Means (KM)	[24], [27]

En [5], se pueden encontrar diferentes colecciones de datos que han sido donadas por varias universidades, agencias y empresas. De esta fuente se obtuvo una colección de datos de vibración que se utilizan en los experimentos divulgados en esta publicación.

En estudios recientes, como el realizado en [2], se han llevado a cabo análisis exhaustivos para extraer características y clasificar fallas utilizando

algoritmos de aprendizaje automático. Los resultados indican que incluso con un conjunto reducido de características estadísticas, éstas pueden ser empleadas en el diseño de sistemas de detección de fallas en rodamientos de alta precisión, siempre y cuando sean calculadas a partir de una ventana de tamaño adecuado.

Es importante resaltar que estos hallazgos tienen implicaciones significativas en la

optimización de la detección temprana de fallas en equipos mecánicos, lo cual puede aumentar su vida útil y reducir los costos de mantenimiento.

El propósito de esta investigación es presentar una técnica de preprocesamiento de datos que considera factores como el origen, el instrumento de medición y las características del equipo evaluado, para poder realizar clasificaciones y predicciones que indiquen el estado de salud o determinen la RUL de los rodamientos colocados en la flecha de un motor eléctrico.

2. Antecedentes

La implementación de técnicas de mantenimiento predictivo (PdM) es una tarea importante en la industria, donde se busca maximizar el tiempo de trabajo de las máquinas y prevenir las paradas no programadas.

Para ello, se utilizan diferentes tecnologías y tipos de sensores para monitorear en tiempo real el estado de los equipos y detectar posibles fallas. El uso de sistemas computacionales y algoritmos de Machine Learning (ML) es altamente beneficioso para manejar grandes cantidades de datos y realizar mejores interpretaciones de la información.

En este sentido el uso de ML es fundamental en la planeación de PdM, como se muestra en [6], donde se utilizan algoritmos para llevar el control del estado de herramientas de corte y motores, o en [7], donde se plantea un sistema de monitoreo ultrasónico basado en ML para buscar fracturas en una turbina eólica.

Además, en [8] y [9] se destaca la importancia de integrar el PdM y el ML en los sistemas de producción industrial para reducir cargas de trabajo, mejorar las planeaciones y evitar paradas no programadas de las máquinas.

La variedad de sensores utilizados en la captura de información, en tiempo real, de las máquinas, requiere diferentes tecnologías para la captura, la recolección y el procesamiento de los datos. En algunos casos se hace uso de varias fuentes de información para tomar decisiones de mantenimiento, como se evidencia en los trabajos presentados en [10–12], donde se utilizan datos de sensores para detectar comportamientos anormales en los equipos. Entre los diferentes

tipos de sensores, el análisis de vibraciones es una técnica ampliamente utilizada para la detección temprana de fallas [13].

En algunos casos, se puede utilizar sólo la información de vibración para determinar la vida útil restante (RUL) de un equipo, como en los trabajos presentados en [14, 15], donde se capturan los datos de vibración y con el uso de técnicas de ML se obtienen patrones de comportamiento para determinar el estado de salud de motores eléctricos.

Los sensores térmicos y acústicos también son utilizados en el mecanizado de piezas para determinar el desgaste en las herramientas de fresado [16], y paralelamente con sensores de vibración determinar la RUL de transformadores de energía eléctrica, así como en sistemas de producción de energía hidroeléctrica. La tabla 1 muestra los diferentes tipos de sensores utilizados en las investigaciones revisadas y los componentes evaluados:

IMU: Unidad de medición inercial,

Motor AC: Motor de corriente alterna.

Es importante destacar que los sensores de vibración son ampliamente utilizados en muchas industrias que requieren máquinas de rotación, tales como bandas transportadoras, sistemas de ventilación, transporte de carga, entre otras.

Debido a sus características se pueden monitorear las máquinas rotativas y sus componentes a través de sensores de vibración, lo que permite un amplio panorama de posibilidades para la implementación de nuevas técnicas de planeación. Existe una gran variedad de algoritmos de Machine Learning. En la tabla 2 se muestran algunos de los mencionados en los trabajos revisados, donde se puede observar cuales son los utilizados en diferentes industrias.

3. Método

Para seleccionar la técnica de preprocesamiento adecuada se revisaron diferentes procedimientos utilizando el conjunto de datos extraído del repositorio [5], y se analizaron las características del origen de los datos descritas en [29], que es el artículo de referencia que proporciona dicha información.

Si bien el proceso para realizar clasificaciones o predicciones mediante ML no es una ley que deba seguirse al pie de la letra, la mayoría de las investigaciones utilizan uno o varios de los pasos siguientes para generar sus modelos: adquisición de datos, limpieza, estandarización, normalización, extracción de características, generación de modelos y validación [30].

Sin embargo, este proceso generalizado parte de los datos crudos (sin ningún tipo de procesamiento) en sí, y no toma en cuenta otros factores que pueden influir en el significado de los datos. Por ejemplo, cómo se obtuvieron los datos, qué tipo de datos son y de qué manera se obtuvieron. Conocer estos factores puede beneficiar el proceso de adaptación de datos antes de generar los modelos de predicción y clasificación.

En los trabajos [30–33], para la creación de modelos de clasificación y predicción se utilizan técnicas similares de preprocesamiento de datos, las que son diferentes a las técnicas utilizadas en esta investigación. En estos trabajos se utilizan técnicas como la transformada de Fourier en tiempo corto, transformada wavelet, transformación de dominio de frecuencia de tiempo, transformada de Hilbert o transformación de sincronización.

Estas técnicas se utilizan para adaptar los datos, para que, al momento de utilizar los diferentes algoritmos, los resultados de estos sean más efectivos. Sin embargo, el tratamiento de datos se realiza como si no se conocieran los orígenes de los mismos, lo que resulta en la realización de una serie de tareas que pueden evitarse.

El enfoque de preprocesamiento propuesto en este trabajo, se basa en el aprovechamiento de la información de origen de los datos para reducir la carga de procesamiento que se realiza para crear los modelos de clasificación y predicción. La colección de datos obtenida cuenta con la información de la máquina de donde se tomaron las mediciones.

La fig. 1 muestra una perspectiva de la ubicación de los rodamientos y la colocación de los sensores.

Se siguieron 4 fases para para la creación de los modelos de clasificación y predicción, la fig. 2 muestra un diagrama de este procedimiento:

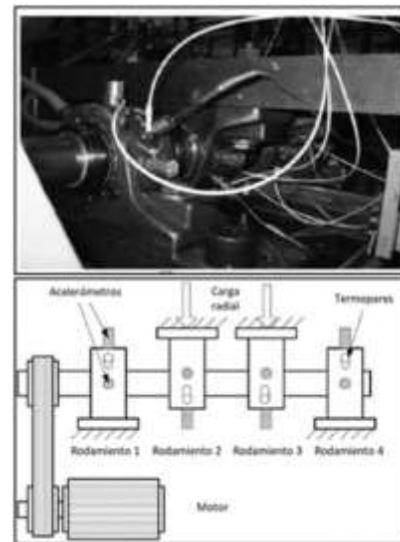


Fig. 1. Banco de pruebas de rodamientos y colocación de sensores [29]

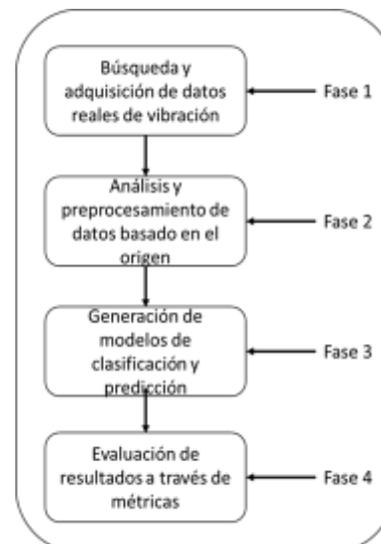


Fig. 2. Desarrollo de los modelos de clasificación y predicción

Fase 1: Adquisición de datos

En esta fase se realiza una lectura de los datos a partir del dataset número 3 que se encuentra en el repositorio [5], este dataset cuenta con 6324 archivos con 20480 registros con señales de vibración de 4 rodamientos, estos corresponden a 44 días de trabajo de la máquina.

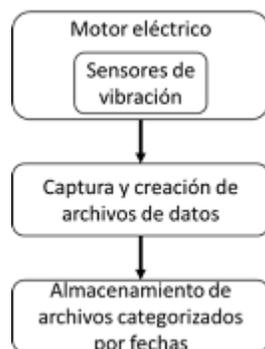


Fig. 3. Fase 1 Adquisición de datos

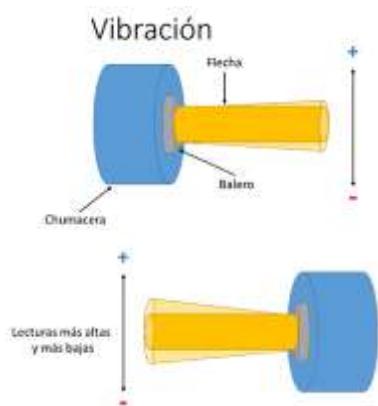


Fig. 4. Baleros y flechas

En la documentación se informa que para adquirir los datos se realizó la toma de lecturas durante diferentes periodos de tiempo según el dataset; al final de estos, en el dataset seleccionado se presenta la falla en el balero número 3. La fig. 3 muestra un diagrama de flujo de la adquisición de datos.

Fase 2: Preprocesamiento

Durante esta fase, se realiza un tratamiento de los datos para obtener un dataset que contenga información representativa de la falla que se produce en el rodamiento.

En primer lugar, se reduce la muestra tomando el 10% de los datos de cada archivo (que contienen los datos recolectados durante 1 segundo entre periodos de 10 minutos). Esto se hace para reducir la cantidad de datos redundantes entre archivos, ya que hay un total de 129 515 520 datos.

A continuación, se extrae la muestra del rodamiento #3, que es el que presenta la falla al final del experimento. El objetivo es eliminar los datos no relevantes a la falla (ver Fig. 5a). Se añade una estampa que indica tiempo y cuál es el archivo de origen para identificar en qué momento del experimento se tomó la lectura.

Posteriormente se realiza una transformación a valores absolutos. Debido a la variabilidad propia de los datos de los sensores, se decidió combinar los datos positivos y negativos para tener una mejor apreciación de los picos que determinan las probabilidades de falla (ver Fig. 4).

Al tomar en cuenta el funcionamiento de los rodamientos y las flechas, existen movimientos que se pueden definir como ascendentes y descendentes, en los cuales se obtienen datos positivos y negativos. En este escenario se determina que a mayor vibración se obtienen picos ascendentes y descendentes con respecto a la dirección del movimiento que detectan los sensores.

Sin embargo, los datos más alejados del punto de origen 0 son los que indican una futura falla, independientemente de si son positivos o no. Para reducir la redundancia de datos en el dataset se realiza el cálculo de la media de los registros correspondientes a cada archivo. De esta manera se obtiene una representación más precisa de los datos de cada archivo sin la necesidad de conservar toda la información redundante.

Con el dataset reducido se crea un nuevo conjunto de datos que consta de 6324 registros. Estos registros corresponden a un total de 1054 horas de trabajo de la máquina, donde la falla en el rodamiento ocurre en la hora 1033, tal como se muestra en la fig. 5b. Este nuevo conjunto de datos se utiliza como base para la generación de modelos de clasificación y predicción de fallas en el rodamiento.

Fase 3: Generación de modelos y experimentación

Se crearon modelos utilizando algoritmos de clasificación como DT, RF y SVM, y para los modelos de regresión se emplearon NN y LR. Se utilizaron muestras del 70% del dataset generado después del preprocesamiento. La experimentación se llevó a cabo en lenguaje Python en la plataforma Google Colab, y los

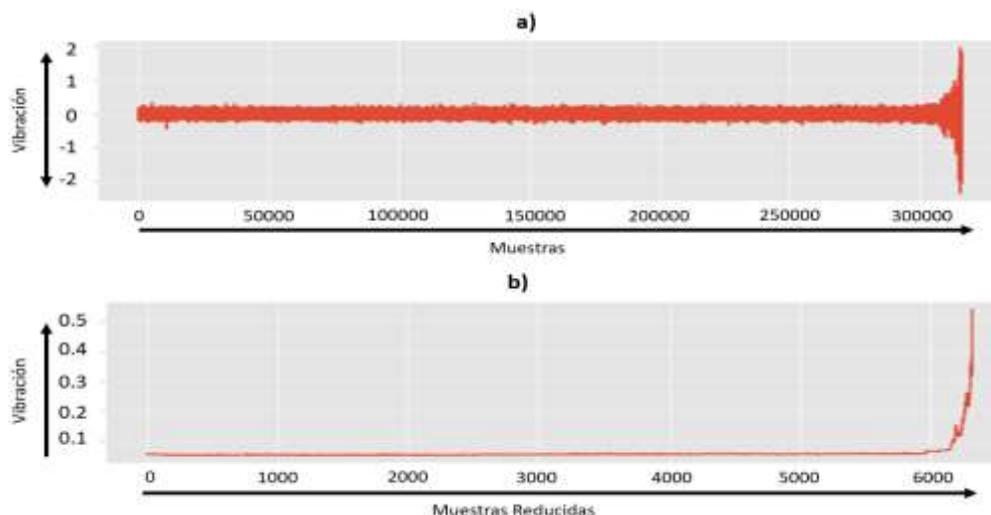


Fig. 5. Datos del rodamiento 3

resultados obtenidos se evaluaron en la fase 4 del estudio.

Fase 4: Evaluación de resultados

En la evaluación de los modelos de clasificación y regresión [32, 33], se utilizan métricas para determinar la eficacia del entrenamiento. Las métricas seleccionadas son las siguientes:

Accuracy: Indica la relación proporcional entre las predicciones realizadas correctamente y el número de instancias evaluadas. Está determinada por la ecuación 1:

$$Accuracy = \frac{tp + tn}{tp + fp + tn + fn}. \quad (1)$$

Precision: Representa la relación de elementos clasificados correctamente con todos los elementos clasificados, alcanza su mejor valor en 1 y la peor puntuación en 0 y está determinada por la ecuación 2:

$$Precision = \frac{tp}{tp + fp}. \quad (2)$$

Recall: Representa la relación entre las instancias correctamente clasificadas contra las instancias originales, alcanza su mejor valor en 1 y la peor puntuación en 0 y está determinada por la ecuación 3:

$$Recall = \frac{tp}{tp + fn}. \quad (3)$$

MSE: En los algoritmos de regresión el MSE promedia el error de predicción al cuadrado para todas las predicciones y encapsula tanto la exactitud como la precisión, alcanza su mejor valor teórico en 0 y está definida por la ecuación 4:

$$MSE = \frac{1}{N} \cdot \sum_{t=1}^N (y_t - f_t)^2. \quad (4)$$

4. Resultados

En esta sección se presentan los resultados de la evaluación de diferentes algoritmos de Machine Learning utilizando el dataset de vibraciones obtenido de [5]. El objetivo principal del estudio fue mejorar el rendimiento de los modelos de clasificación y regresión mediante un preprocesamiento de datos basado en el origen y características de los sensores.

Los resultados muestran que el preprocesamiento de datos utilizando el método propuesto ha mejorado significativamente los modelos de Machine Learning creados con este dataset, en comparación con los modelos creados utilizando los datos en crudo en los distintos algoritmos evaluados. Esto sugiere que el preprocesamiento ha sido beneficioso para

mejorar la precisión y capacidad de predicción de los modelos.

La Tabla 3 muestra los resultados de las métricas de evaluación para los modelos de clasificación y regresión. Se observa que, con los datos en crudo, la exactitud alcanza un máximo del 26%, mientras que en otros estudios previos se ha obtenido hasta un 95% y un 96% de precisión. Sin embargo, al utilizar el método propuesto se logró mejorar la exactitud hasta un 96%.

Para los algoritmos de regresión, los resultados muestran que con el método propuesto la predicción de fallas se amplió a una ventana de tiempo de 8,240 min., en comparación con los 4,725 min. obtenidos en [31] lo cual es una diferencia a favor de 3,515 min. esto representa un adelanto del 74.4% en el tiempo para la planificación del mantenimiento.

Utilizando la información proporcionada por [1] se puede determinar que utilizando el método propuesto se puede generar un ahorro de hasta 5,356,000 dólares en costos de mantenimiento (650 dólares por minuto) para las fábricas que producen bienes de consumo de rápido movimiento y un ahorro de hasta 274,666,639 dólares en el sector automotriz.

En resumen, los resultados obtenidos demuestran que el preprocesamiento de datos propuesto mejora significativamente el rendimiento de los modelos de Machine Learning en comparación con otros trabajos relacionados, lo que sugiere que la técnica es prometedora para la optimización de la predicción de fallas en rodamientos.

Esta técnica puede ser aplicada en otros sistemas de monitoreo de vibraciones para mejorar la precisión y capacidad de predicción de los modelos de Machine Learning:

Alg: Algoritmo utilizado,

Mse: Métrica MSE,

Ac: Métrica Accuracy,

Ps: Métrica Precision,

Rc: Métrica Recall.

5. Discusión

En la literatura existen distintos enfoques para el preprocesamiento de datos en problemas de

Tabla 3. Resultados

Dataset	Alg	Mse	Ac	Ps	Rc
Original al 10%	LR	8.26	-	-	-
	NN	7.5	-	-	-
	DT	-	0.26	0.26	0.26
	RF	-	0.28	0.29	0.29
	SVM	-	0.31	0.31	0.31
[32]	CNN	-	0.95	-	-
	NN	0.0172	-	-	-
[33]	NN	-	0.93	-	-
[31]	NN	-	0.96	-	-
Método propuesto	LR	0.0325	-	-	-
	NN	0.0019	-	-	-
	DT	-	0.92	0.93	0.92
	RF	-	0.92	0.93	0.92
	SVM	-	0.96	0.96	0.94

diagnóstico de fallas utilizando técnicas de ML. Si bien es fundamental realizar procesos de limpieza y normalización de los datos, algunos procesos como el agrupamiento o escalamiento pueden eliminar o comprometer información importante.

Además, hay trabajos que han utilizado la transformación de señales de vibración analógicas en imágenes para poder aplicar algoritmos de análisis de imágenes, lo cual puede forzar la adaptación de los datos y comprometer la información.

Como se menciona en [32], es importante adaptar los datos para obtener mejores resultados en los modelos de ML, pero no se deben forzar los mismos para “encajar” en los algoritmos, ya que esto puede comprometer la información.

Por otro lado, el conocimiento sobre el comportamiento de los rodamientos al presentar fallas puede ser de gran utilidad en el tratamiento de los datos, ya que se pueden evitar procesos innecesarios o utilizar alternativas con menor costo computacional.

6. Conclusiones y trabajos futuros

En este trabajo se ha presentado un preprocesamiento de datos para la creación de modelos de clasificación y regresión, con el objetivo de obtener mejores clasificaciones y predicciones para evitar posibles fallas en los rodamientos de las máquinas.

Los resultados obtenidos demuestran que el preprocesamiento con técnicas alternativas es efectivo para tratar este tipo de información, lo que puede ser de gran utilidad para la planificación de mantenimiento.

Se ha demostrado que el uso del método propuesto no compromete el funcionamiento de los algoritmos al crear los modelos y que es posible realizar adaptaciones necesarias siempre y cuando no se comprometa la información fundamental. Además, se concluye que el conocimiento del origen y la forma de recolectar los datos son fundamentales para obtener información valiosa que beneficie el tratamiento de los mismos.

En cuanto a trabajos futuros, se propone extender este enfoque de preprocesamiento a otros tipos de maquinarias y fuentes de datos para evaluar su comportamiento en diferentes escenarios. También se puede investigar la aplicación de otras técnicas de preprocesamiento y algoritmos de ML para comparar y evaluar su desempeño.

Agradecimientos

Esta investigación fue apoyada por el Consejo Nacional de Humanidades Ciencias y Tecnologías (CONAHCYT) y por el Tecnológico Nacional de México (TecNM), campus Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET).

Referencias

1. **Johnson, E. (2023).** The true cost of downtime. Siemens.
2. **Van-Horenbeek, A., Pintelon, L. (2013).** A dynamic predictive maintenance policy for complex multi-component systems. *Reliability engineering & system safety*, Vol. 120, pp. 39–50. DOI: 10.1016/j.ress.2013.02.029.
3. **Liu, S. F., Fan, Y. J., Luh, D. B., Teng, P. S. (2022).** Organizational culture: the key to improving service management in industry 4.0. *Applied Sciences*, Vol. 12, No. 1. DOI: 10.3390/app12010437.
4. **BRRMX (2022).** 10 fallas en los rodamientos y sus causas - BRR Binasá. <https://brr.mx/10-fallas-en-los-rodamientos-y-sus-causas/>.
5. **NASA (2022).** Prognostics center of excellence - Data repository. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>.
6. **Lee, W. J., Wu, H., Yun, H., Kim, H., Jun, M. B., Sutherland, J. W. (2019).** Predictive maintenance of machine tool systems using artificial intelligence techniques applied to machine condition data. *Procedia CIRP*, Vol. 80, pp. 506–511. DOI: 10.1016/j.procir.2018.12.019.
7. **Galarza-Urigoitia, N., Rubio-García, B., Gascón-Álvarez, J., Aznar-Lapuente, G., Olite-Biurrun, J., López-Germán, A., Rubio-Botía, J. (2019).** Predictive maintenance of wind turbine low-speed shafts based on an autonomous ultrasonic system. *Engineering Failure Analysis*, Vol. 103, pp. 481–504. DOI: 10.1016/j.engfailanal.2019.04.048.
8. **Cho, S., May, G., Tourkogiorgis, I., Perez, R., Lazaro, O., de-La-Maza, B., Kiritsis, D. (2018).** A hybrid machine learning approach for predictive maintenance in smart factories of the future. *Advances in Production Management Systems. Smart Manufacturing for Industry 4.0: IFIP WG 5.7 International Conference, APMS 2018, Seoul, Korea, Proceedings, Part II* Springer International Publishing. Vol. 536, pp. 311–317. DOI: 10.1007/978-3-319-99707-0_39.
9. **Palau, A. S., Dhada, M. H., Bakliwal, K., Parlikad, A. K. (2019).** An industrial multi agent system for real-time distributed collaborative prognostics. *Engineering Applications of Artificial Intelligence*, Vol. 85, pp. 590–606. DOI: 10.1016/j.engappai.2019.07.013.

10. **Abbasi, T., Lim, K. H., Yam, K. S. (2019).** Predictive maintenance of oil and gas equipment using recurrent neural network. IOP Conference Series: Materials Science and Engineering, Vol. 495, p. 012067. DOI: 10.1088/1757-899X/495/1/012067.
11. **Aivaliotis, P., Georgoulas, K., Chryssolouris, G. (2017).** A RUL calculation approach based on physical-based simulation models for predictive maintenance. International Conference on Engineering, Technology and Innovation, pp. 1243–1246. DOI: 10.1109/ICE.2017.8280022.
12. **Selcuk, S. (2017).** Predictive maintenance, its implementation and latest trends. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, Vol. 231, No. 9, pp. 1670–1679. DOI: 10.1177/0954405415601640.
13. **Li, W. F., Xie, D. M., Qian, Y., Zhao, X. B., Cai, S., Hou, Y. M. (2010).** Calculation of rotor's torsional vibration characteristics based on equivalent diameter of stiffness. 2010 Asia-Pacific Power and Energy Engineering Conference IEEE. pp. 1–4. DOI: 10.1109/APP-EEC.2010.5449178.
14. **Durbhaka, G. K., Selvaraj, B. (2016).** Predictive maintenance for wind turbine diagnostics using vibration signal analysis based on collaborative recommendation approach. International Conference on Advances in Computing, Communications and Informatics, pp. 1839–1842. DOI: 10.1109/ICA-CCI.2016.7732316.
15. **Kiangala, K. S., Wang, Z. (2018).** Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts. The International Journal of Advanced Manufacturing Technology, Vol. 97, No. 9, pp. 3251–3271. DOI: 10.1007/s00170-018-2093-8.
16. **Traini, E., Bruno, G., D'antonio, G., Lombardi, F. (2019).** Machine learning framework for predictive maintenance in milling. IFAC-PapersOnLine, Vol. 52, No. 13, pp. 177–182. DOI: 10.1016/j.ifacol.2019.11.172.
17. **Kabir, F., Foggo, B., Yu, N. (2018).** Data driven predictive maintenance of distribution transformers. China international conference on electricity distribution, CICED, pp. 312–316. DOI: 10.1109/CICED.2018.8592417.
18. **Aivaliotis, P., Georgoulas, K., Chryssolouris, G. (2017).** A RUL calculation approach based on physical-based simulation models for predictive maintenance. International Conference on Engineering, Technology and Innovation, pp. 1243–1246. DOI: 10.1109/ICE.2017.8280022.
19. **Novoa, C. G., Berríos, G. A. G., Söderberg, R. A. (2017).** Predictive maintenance for motors based on vibration analysis with compact rio. IEEE Central America and Panama Student Conference, IEEE, pp. 1–6. DOI: 10.1109/CONESCAPAN.2017.8277603.
20. **Apiletti, D., Barberis, C., Cerquitelli, T., Macii, A., Macii, E., Poncino, M., Ventura, F. (2018).** iSTEP, an integrated self-tuning engine for predictive maintenance in industry 4.0. IEEE Intl Conf on Parallel & Distributed Processing with Applications, Ubiquitous Computing & Communications, Big Data & Cloud Computing, Social Computing & Networking, Sustainable Computing & Communications, pp. 924–931. DOI: 10.1109/BDCloud.2018.00136.
21. **Cachada, A., Barbosa, J., Leitño, P., Grcaldcs, C. A., Deusdado, L., Costa, J., Romero, L. (2018).** Maintenance 4.0: intelligent and predictive maintenance system architecture. IEEE 23rd international conference on emerging technologies and factory automation, ETFA, Vol. 1, IEEE, pp. 139–146. DOI: 10.1109/ETFA.2018.8502489.
22. **Larrinaga, F., Fernandez-Anakabe, J., Zugasti, E., Garitano, I., Zurutuza, U., Olaizola, J., Mondragon, M. (2019).** A big data implementation of the MANTIS reference architecture for predictive maintenance. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, Vol. 233, No. 10, pp. 1361–1375. DOI: 10.1177/0959651819835362.
23. **Mathew, V., Toby, T., Singh, V., Rao, B. M., Kumar, M. G. (2017).** Prediction of remaining useful lifetime (RUL) of turbofan engine using machine learning. IEEE international

- conference on circuits and systems, pp. 306–311. DOI: 10.1109/ICCS1.2017.8326010.
24. **Santiago, A. R., Antunes, M., Barraca, J. P., Gomes, D., Aguiar, R. L. (2019).** Predictive maintenance system for efficiency improvement of heating equipment. IEEE Fifth International Conference on Big Data Computing Service and Applications, IEEE, pp. 93–98. DOI: 10.1109/BigDataService.2019.00019.
 25. **Sezer, E., Romero, D., Guedea, F., Macchi, M., Emmanouilidis, C. (2018).** An industry 4.0-enabled low cost predictive maintenance approach for SMEs. IEEE International Conference on Engineering, Technology and Innovation pp. 1–8. DOI: 10.1109/ICE.2018.8436307.
 26. **Werner, A., Zimmermann, N., Lentz, J. (2019).** Approach for a holistic predictive maintenance strategy by incorporating a digital twin. Procedia Manufacturing, Vol. 39, pp. 1743–1751. DOI: 10.1016/j.promfg.2020.01.265.
 27. **Canizo, M., Onieva, E., Conde, A., Charramendieta, S., Trujillo, S. (2017).** Real-time predictive maintenance for wind turbines using Big Data frameworks. IEEE International Conference on Prognostics and Health Management. pp. 70–77. DOI: 10.1109/ICPHM.2017.7998308.
 28. **Qiu, H., Lee, J., Lin, J., Yu, G. (2006).** Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics. Journal of Sound and Vibration, Vol. 289, No. 4, pp. 1066–1090. DOI: 10.1016/j.jsv.2005.03.007.
 29. **Fan, C., Chen, M., Wang, X., Wang, J., Huang, B. (2021).** A review on data preprocessing techniques toward efficient and reliable knowledge discovery from building operational data. Frontiers in energy research, Vol. 9, p. 652801. DOI: 10.3389/fenrg.2021.652801.
 30. **Ahmad, W., Khan, S. A., Kim, J. M. (2017).** A hybrid prognostics technique for rolling element bearings using adaptive predictive models. IEEE Transactions on Industrial Electronics, Vol. 65, No. 2, pp. 1577–1584. DOI: 10.1109/TIE.2017.2733487.
 31. **Jiao, J., Zhao, M., Lin, J., Liang, K. (2020).** A comprehensive review on convolutional neural network in machine fault diagnosis. Neurocomputing, Vol. 417, pp. 36–63. DOI: 10.1016/j.neucom.2020.07.088.
 32. **Ali, J. B., Fnaiech, N., Saidi, L., Chebel-Morello, B., Fnaiech, F. (2015).** Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. Applied Acoustics, Vol. 89, pp. 16–27. DOI: 10.1016/j.apacoust.2014.08.016.

Article received on 11/04/2024; accepted on 17/10/2024.

**Corresponding author is Máximo López Sánchez.*