

Revisión de alcance: evaluación de técnicas de aprendizaje automático en el mantenimiento predictivo

		Machine			
		Class I small machines	Class II medium machines	Class III large rigid foundation	Class IV large soft foundation
	Vibration Velocity Wms				
	0,01				
	0,02				
	0,03				
	0,04				
	0,07				
	0,11				
	0,18				
	0,28				
	0,44				
	0,70				
	0,71				
	1,10				

Screening of machine learning techniques on predictive maintenance: a scoping review



Daniel Campos-Olivares¹, Alejandro Carrasco-Muñoz¹, Mirko Mazzoleni², Antonio Ferramosca² y Amalia Luque-Sendra³

¹ Universidad de Sevilla. Escuela de Ingeniería de Computadores. Departamento de Tecnología Electrónica. Avda. Reina Mercedes - 41011 Sevilla (España).

² Universidad de Bérgamo. Departamento de Gestión, Información e Ingeniería de Producción. Via Marconi, 5 - 24044 Dalmine (Italia).

³ Universidad de Sevilla. Escuela Politécnica Superior. Departamento de Ingeniería de Diseño. Calle Virgen de África, 7 - 41011 Sevilla (España).

DOI: <https://doi.org/10.6036/10950> | Recibido: 08/may/2023 • Inicio Evaluación: 27/jun/2023 • Aceptado: 05/sep/2023

To cite this article: CAMPOS-OLIVARES, Daniel; CARRASCO-MUÑOZ, Alejandro; MAZZOLENI, Mirko; FERRAMOSCA, Antonio; LUQUE-SENDRA, Amalia. SCREENING OF MACHINE LEARNING TECHNIQUES ON PREDICTIVE MAINTENANCE: A SCOPING REVIEW. *DYNA*. March - Abril. vol. 99, n.2, pp. 159-165. DOI: <https://doi.org/10.6036/10950>

FINANCIACIÓN

Cátedra Telefónica en Redes Inteligentes, Universidad de Sevilla
Cátedra Indra "Digital Society", Universidad de Sevilla
Cátedra "la Ingeniería en la Industria Agroalimentaria - GOYA - Antonio Unanue"
VII Plan Propio de Investigación y Transferencia de la Universidad de Sevilla (Proyectos 2023/00000378 y 2023/00000390)

ABSTRACT

Predictive maintenance (PdM) is a set of actions and techniques to early detect failures and defects on machines before they occur, and the usage of machine learning and deep learning techniques in predictive maintenance has increased during the last years. Even with this increase of the literature, there is still a gap concerning the application of such techniques for PdM in the industry, as there are no clear guidelines about which information to use for a PdM system, how to process the information, and what machine learning techniques should be used in order to obtain acceptable results. This scoping review is performed in order to observe the current status on the use of Machine Learning and Deep Learning in predictive maintenance in academia and provide answer to the questions related to these guidelines. For this purpose, a literature review of the last five years is carried out, using those articles that cover information about sources of information used for PdM, the treatment given to such data and the machine learning (ML) methods or techniques used.

The Web of Science: Core Collection database is used as a source of information, specifically the Science Citation Index Expanded (SCIE). The review shows that there are different information sources used for machine learning and deep learning in PdM, depending on the origin of the data and the availability of it, and as well whether the data sets are private or public. Also, we can observe that data used for both training and making predictions does not only use traditional pre-processing techniques, but that about one fifth of the articles even propose new techniques in this field. Additionally, we compare a wide range of techniques and algorithms which are used in Deep Learning -being ANN the most used- and in Machine Learning, being SVM the most used algorithm, closely followed by Random Forest. Based on the results, we provide indications about how to apply ML for PdM in industry.

• **Keywords:** machine learning, predictive maintenance, artificial intelligence, deep learning, data processing, data collection.

RESUMEN

El mantenimiento predictivo (PdM) es un conjunto de acciones y técnicas para detectar tempranamente fallos y defectos en máquinas antes de que ocurran. El uso de técnicas de aprendizaje automático y aprendizaje profundo en el mantenimiento predictivo ha aumentado en los últimos años. A pesar de este aumento en la literatura, todavía existe una brecha en cuanto a la aplicación de tales técnicas en la industria, ya que no existen pautas claras sobre qué información utilizar en un sistema de PdM, cómo procesar la información y qué técnicas de aprendizaje automático se deben usar para obtener resultados aceptables. Esta revisión de alcance se realiza para observar el estado actual del uso del aprendizaje automático y el aprendizaje profundo en el mantenimiento predictivo en la academia y proporcionar respuestas a las preguntas relacionadas con estas pautas. Para este propósito, se lleva a cabo una revisión de la literatura de los últimos cinco años, utilizando los artículos que cubren información sobre las fuentes de información utilizadas para el PdM, el tratamiento dado a dichos datos y los métodos o técnicas de aprendizaje automático (ML) utilizados.

La base de datos Web of Science: Core Collection se utiliza como fuente de información, específicamente el Science Citation Index Expanded (SCIE). La revisión muestra que existen diferentes fuentes de información utilizadas para el aprendizaje automático y el aprendizaje profundo en el PdM, dependiendo del origen de los datos y su disponibilidad, así como si los conjuntos de datos son privados o públicos. Además, podemos observar que los datos utilizados tanto para el entrenamiento como para realizar predicciones no solo utilizan técnicas de preprocesamiento tradicionales, sino que aproximadamente una quinta parte de los artículos incluso proponen nuevas técnicas en este campo. Además, comparamos una amplia gama de técnicas y algoritmos que se utilizan en el Aprendizaje Profundo, siendo las Redes Neuronales Artificiales (ANN) las más utilizadas, y en el Aprendizaje Automático, siendo el SVM (Máquinas de Soporte Vectorial) el algoritmo más utilizado, seguido de cerca por Random Forest. Basándonos en los resultados, proporcionamos indicaciones sobre cómo aplicar el Aprendizaje Automático para Mantenimiento Predictivo en la industria.

• **Palabras clave:** aprendizaje automático, mantenimiento predictivo, inteligencia artificial, aprendizaje profundo, procesamiento de datos, recolección de datos.

1. INTRODUCCIÓN

El mantenimiento predictivo es un conjunto de acciones y técnicas realizadas con el objetivo de detectar posibles fallos y defectos de las máquinas en sus etapas iniciales, con el fin de prevenir que estos fallos se manifiesten de manera más significativa durante la operación, causando paradas de emergencia y tiempo de inactividad. Su misión es mantener un cierto nivel de servicio en el equipo programando revisiones en el momento más oportuno.

Mientras que el mantenimiento predictivo actual reduce las averías en un 70% y disminuye los costos de mantenimiento en un 25% [1], todavía existe margen de mejora en este campo. Los avances recientes han llevado a la instalación de sensores que recopilan información en tiempo real sobre el estado de la maquinaria, y aquí es donde el aprendizaje automático puede proporcionar una ventaja significativa: utilizando los datos recopilados por esos sensores y entrenando modelos que ayudarían a anticiparse a los accidentes y errores imprevistos.

Uno de los problemas a los que se enfrentan las empresas que deciden incorporar el mantenimiento predictivo en su negocio es la falta de un proceso claro sobre cómo integrarlo. Un problema adicional que podemos identificar es la falta de pautas sobre cómo integrar este mantenimiento en un flujo de trabajo junto con algoritmos de aprendizaje automático. Si bien la integración del mantenimiento predictivo en una empresa utilizando el aprendizaje automático puede parecer una tarea compleja, podemos dividirla en siete etapas que generalmente abarcan cualquier proyecto de aprendizaje automático:

1. Recopilación de datos
2. Preparación de datos
3. Selección del modelo
4. Entrenamiento del modelo
5. Evaluación del modelo
6. Ajuste de parámetros
7. Realización de predicciones

Mientras que existe una gran cantidad de literatura sobre cómo entrenar, evaluar y ajustar un modelo concreto una vez que este ha sido elegido, identificamos una laguna en las tres etapas iniciales en el ámbito de los problemas de mantenimiento predictivo. Como resultado de esta situación, podemos transformar cada uno de estos puntos en preguntas clave a las cuales nos gustaría proporcionar respuestas en este artículo:

- Q1. ¿Qué fuentes de información se utilizan comúnmente en mantenimiento predictivo?
- Q2. ¿Qué tratamiento se le da a la información que se utiliza en mantenimiento predictivo?
- Q3. ¿Qué tipo de métodos de aprendizaje automático se utilizan en mantenimiento predictivo?

La relación de las secciones en las que este artículo cubre las contribuciones y respuestas a estas preguntas se puede ver en la Tabla 1.

Debido a los requisitos de formato, las referencias utilizadas en las diferentes secciones de contribuciones se proporcionan en los materiales adicionales.

Pregunta	Sección de Contribuciones	Sección de Discusión
Q1	3.4	4.1
Q2	3.5	4.2
Q3	3.6	4.3

Tabla 1. Preguntas de investigación y discusión.

La maquinaria industrial y los equipos producen una gran cantidad de información que se puede recopilar a través de sensores y a través de los registros propios del equipo. La pregunta es que, de toda esta información disponible, es necesario *identificar cuál es la más interesante para realizar tareas de mantenimiento predictivo*, así como la relación de esta información con las posibles interrupciones que pueden afectar el funcionamiento normal del equipo.

Además, no solo es importante qué tipo de información se selecciona para realizar esta tarea, sino también cómo se tratará, lo que dependerá en gran medida de cómo se recopilan los datos, qué modelos de aprendizaje automático se utilizarán para hacer las predicciones, así como el procesamiento necesario de los datos en caso de que el conjunto de datos tenga valores faltantes debido a la pérdida de datos u otras razones.

Finalmente, una vez que hemos seleccionado y procesado los datos que deseamos utilizar, es importante seleccionar los modelos que funcionen mejor para este problema en particular y que ofrezcan niveles aceptables de precisión para que la inclusión del mantenimiento predictivo en los flujos de trabajo de la organización tenga un retorno de inversión positivo para la organización.

Esta revisión de literatura busca proporcionar respuestas a las preguntas presentadas, utilizando como base los estudios científicos realizados durante los últimos cinco años. Antes de llevar a cabo esta revisión sistemática, se realizó una búsqueda de revisiones previas que pudieran proporcionar una respuesta completa a las preguntas planteadas. Para la búsqueda de revisiones previas, se utilizó la plataforma **Web of Science** y **Scopus**. Dentro de esta búsqueda, se encontraron algunos artículos relevantes que cubren parcialmente las preguntas de investigación planteadas. El primero de ellos, publicado en 2020 por un equipo de investigadores de la República Popular de China, muestra una revisión exhaustiva y una hoja de ruta de las técnicas de aprendizaje automático aplicadas al diagnóstico de fallas hasta 2020 [2], pero como veremos en la sección 3.1, la cantidad de literatura sobre este tema en los últimos dos años ha aumentado considerablemente, siendo el número de publicaciones mayor que en los diez años anteriores. Debido a esto, consideramos que se necesitaba una revisión más actualizada. Por otro lado, hay un artículo más reciente publicado en marzo de 2021 por un equipo de investigadores del Instituto Nacional de Tecnología Warangal en India, que revisa los algoritmos de aprendizaje automático más comúnmente utilizados [3], pero no profundiza en la tipología de los datos que deben recopilarse ni en el tratamiento que debe darse a los datos para maximizar los resultados de los algoritmos. Además, en la investigación sobre los últimos artículos que realizaron una revisión previa de las técnicas de aprendizaje automático aplicadas al mantenimiento predictivo, encontramos artículos sobre el diseño de algoritmos de aprendizaje automático basados en los datos [4], la visualización de resultados de clasificación [5] o las consideraciones de problemas de diagnóstico de fallas para un campo concreto como los actuadores electromecánicos aéreos [6], que también analizan la literatura sobre este tema, pero para responder a diferentes preguntas de investigación.

El objetivo principal de proporcionar respuestas a las preguntas de investigación previamente presentadas es conocer cuál es el estado actual de la investigación con respecto a la aplicación de metodologías y técnicas de aprendizaje automático en el mantenimiento predictivo, para que sirva como base para futuras investigaciones con el fin de proporcionar un marco funcional y confiable para la industria en este tema.

2. MATERIALES Y MÉTODOS

2.1. PROTOCOLO

Como estrategia de búsqueda en el índice SCIE, buscaremos los dos temas principales de los cuales deseamos obtener resultados:

- Aprendizaje Automático (Machine Learning)
- Mantenimiento Predictivo (Predictive Maintenance)

Por lo tanto, consultaremos la intersección entre la literatura sobre ambos temas (en inglés):

PREDICTIVE MAINTENANCE Ç MACHINE LEARNING

De acuerdo con las fuentes de información seleccionadas, marcaremos el índice SCIE (o SCI-EXPANDED) como el único índice de búsqueda y, de acuerdo con los criterios de exclusión, solo seleccionaremos entradas de los últimos 5 años.

Con base en esto, los términos de búsqueda y filtros a utilizar son los siguientes:

Topic	"PREDICTIVE MAINTENANCE" AND "MACHINE LEARNING"
Time span	Last 5 years
Indexes	SCI-EXPANDED

Para el proceso de selección, primero realizamos un filtrado adicional teniendo en cuenta otros criterios de exclusión:

- E1. Descartar resultados que no sean artículos
- E2. Descartar resultados que no traten sobre aplicaciones de aprendizaje automático para mantenimiento predictivo

Para descartar resultados basados en el criterio de exclusión E2, la selección de los resultados con respecto al tema que cubren se realizará manualmente en función del contenido del resumen de estos. Este proceso de selección consta de dos pasos, en los cuales inicialmente dos de los autores realizan una selección con una cantidad reducida de los mismos resultados. Posteriormente, se comparan los resultados de la selección y, en caso de que la diferencia entre las selecciones individuales sea mínima, un único revisor continúa realizando la selección de los artículos restantes. Por otro lado, si las diferencias entre la literatura seleccionada son considerablemente distintas, se lleva a cabo una discusión interna para alinear el alcance de la revisión.

El objetivo de este proceso, aunque pueda parecer redundante al principio, es reducir los recursos necesarios para realizar la selección inicial, ya que las revisiones de alcance requieren un proceso ágil para ser oportunas y relevantes.

La recuperación de información de los artículos se llevará a cabo mediante una tabla de extracción que contenga elementos que cubran información relevante para las preguntas de investigación previamente propuestas:

Los elementos que se recuperarán de los artículos son los siguientes:

- Nombre del artículo.
- Autores del artículo.
- Año de publicación.
- Tema del estudio. (Tabla 3)
- Método de adquisición de datos. (Sección 3.4)
- Tratamiento de datos. (Sección 3.5)
- Mecanismos de aprendizaje profundo utilizados. (Tabla 4)
- Mecanismos de aprendizaje automático utilizados. (Tabla 5)

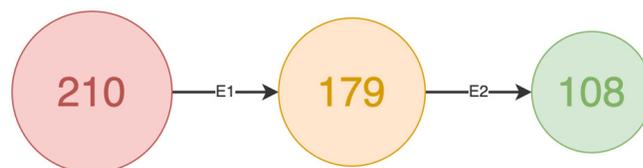


Figura 1. Proceso de selección utilizando los criterios de exclusión definidos.

Esta recuperación se realiza de manera cíclica, en la que se realiza una lectura inicial de todos los artículos involucrados en una primera iteración y luego se revisa en iteraciones sucesivas la lista de artículos para comparaciones o clasificaciones con respecto a los diferentes elementos mencionados anteriormente.

Los resultados más relevantes de la extracción de cada elemento se ofrecen en este artículo.

3. RESULTADOS

Esta sección se ocupa de los resultados de la revisión bibliográfica y bibliométrica de los artículos seleccionados.

Como se puede observar en la Figura 1, el filtro inicial aplicado a la herramienta de refinamiento (E1) reduce la cantidad de literatura analizada de 210 a 179 entradas (aproximadamente un 14.76%), mientras que la exclusión basada en la revisión manual de los resúmenes (E2) concluye con un total de 108 artículos, que son los que se cubren en esta revisión de alcance.

En primer lugar, abordamos la revisión bibliométrica, que incluye secciones como las tendencias de publicación sobre este tema a lo largo de los años y cuáles son las áreas de investigación más involucradas.

3.1. AÑOS DE PUBLICACIÓN

Como se puede observar en la Figura 2, existe una clara tendencia creciente en la publicación de artículos sobre este tema, siendo el año 2021 el año con el mayor número de artículos.

El creciente interés en el tema por parte de la academia refuerza la idea de que la propuesta de llevar a cabo una revisión de la literatura relacionada será de gran utilidad para los futuros investigadores.

3.2. ÁREAS DE INVESTIGACIÓN

Dentro de las áreas de investigación en cuyo contexto se han publicado los artículos mencionados, podemos observar en la Tabla 2 un predominio en el campo de **Ingeniería**, seguido por el campo de **Ciencias de la Computación**.

Como se puede observar, la suma de todos los artículos según las categorías es mayor que el número de artículos revisados, lo

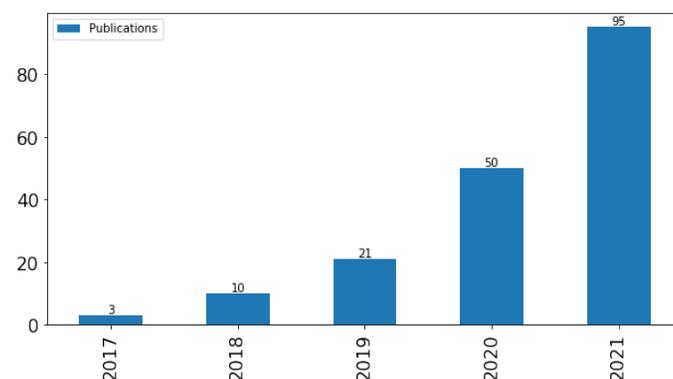


Figura 2. Publicaciones durante los años.

Área de Investigación	Publicaciones
Ingeniería	120
Ciencias de la Computación	61
Química	27
Telecomunicaciones	20
Fuentes de Energía	19
Instrumentos e Instrumentación	17
Ciencia de los Materiales	17
Física	17
Investigación Operativa y Ciencias de la Gestión	16
Automatización y Sistemas de Control	14
Ciencia y Tecnología (otros temas)	10
Construcción y Tecnología de Edificios	5
Ciencias Ambientales y Ecología	5
Termodinámica	5
Oceanografía	4
Matemáticas	2
Ciencia y Tecnología Nuclear	3
Óptica	2
Robótica	2

Tabla 2. Número de artículos según área de investigación.

que sugiere que es posible que los artículos pertenezcan a más de un área de investigación.

3.3. SUJETOS DE ESTUDIO

Lo más importante al identificar las fuentes de datos utilizadas en los estudios revisados es identificar el tema del estudio. Además, es importante identificar si los modelos predictivos se basan en un *fenómeno o medición específica*, como la vibración de una parte de la maquinaria [7], o si se tiene en cuenta *la relación entre un conjunto de mediciones*, conocidas o no, como la relación entre la temperatura y el flujo de líquido en el tanque de un intercambiador de calor, como se describe en [8].

En la Tabla 3, se puede observar la información relacionada con los temas de estudio, así como el fenómeno que estudian. Esta tabla no incluye todos los resultados de la revisión, ya que muchos de ellos no contemplan temas de estudio específicos, sino propuestas de marcos y metodologías para la recopilación de información o la aplicación de modelos de aprendizaje dentro de un campo específico.

3.4. MÉTODOS DE ADQUISICIÓN DE DATOS

Una vez que hemos identificado los temas de estudio en los que se realiza el mantenimiento predictivo, hay otra distinción que debemos tener en cuenta cuando hablamos del origen de las fuentes de información, y es el método de recopilación de datos. Dentro de los artículos revisados, podemos hacer distinciones en función de si los artículos utilizan conjuntos de datos abiertos o privados para su investigación. Mientras que en los que utilizan fuentes abiertas, predominan los conjuntos de datos sintéticos generados por software de simulación, en los conjuntos de datos privados podemos ver dos formas diferentes de recopilar los datos: basados en la recopilación automatizada mediante sensores o inspecciones humanas.

3.4.1. CONJUNTOS DE DATOS ABIERTOS

Entre los repositorios más utilizados, destaca el conjunto de datos de simulación de degradación del motor turbofán **ofrecido por el Centro de Excelencia en Prognósticos de la NASA (PCoE)**, que se utiliza en el 14.81% del número total de artículos. Este conjunto de datos sintéticos se genera con el modelo diná-

Sujeto de Estudio	Fenómeno Estudiado	Número de Artículos
Motor turbofán	Varios	14
Estación de bombeo	Vibración	3
	Temperatura	1
	Presión	1
Aerogenerador	Varios	4
	Vibración	1
	Pruebas ultrasónicas	1
	Datos SCADA	4
Ferrocarril	Varios	3
	Aceleración	1
Maquinaria rotativa	Varios	4
	Imágenes infrarrojas	1
Carretera	Varios	1
	Imágenes	1
Vehículo (coches)	Varios	3
Buque de carga	Varios	2
Herramienta de corte de metal	Varios	2
Tren	Temperatura	1
Instalación de HVAC	Varios	1
Máquina de rectificado	Fallo en el rodamiento	1
Intercambiador de calor	Varios	1
Bulldozer	Vibración	1
Pala mecánica	Vibración	1
Retroexcavadora	Vibración	1
Puente	Estado del tablero	1
Clima interior	Varios	1
Herramienta de corte por chorro de agua	Varios	1
Adsorbente	Varios	1
Motor de transportador	Imágenes	1
Bobina calefactora	Varios	1
Ventilador radial	Varios	1
CEDM	Corriente de la bobina	1
SOV	Forma de onda de corriente alterna	1
Motor de corriente continua sin escobillas	Vibración	1
PTU	Dimensiones de arandela	1
APS	Varios	1
VIA	Vibración	1

Tabla 3. Número de artículos según sujeto de estudio.

mico Commercial Modular Aero-Propulsion System Simulation (C-MAPSS).

3.4.2. CONJUNTOS DE DATOS PRIVADOS

En los artículos que utilizan sus propios conjuntos de datos, los métodos de recopilación de datos se pueden dividir en *conjuntos de datos basados en datos de sensores* y *conjuntos de datos basados en inspecciones humanas*.

Conjuntos de datos basados en **datos históricos de sensores**: Los artículos que utilizan datos históricos, en cualquier formato, recopilados automáticamente por sensores. Estos constituyen la mayoría de los artículos que utilizan conjuntos de datos privados e incluyen tanto datos extraídos por Big Data de grandes industrias como información recopilada de sensores en instalaciones más pequeñas.

De los artículos que utilizan datos históricos de sensores, algunos de ellos, además de estos conjuntos de datos para fines de entrenamiento, utilizan flujos de datos en tiempo real para probar y validar su propuesta. Estos representan el 8.34% de los casos (9 en total).

Conjuntos de datos basados en **datos históricos de inspección**: Artículos que utilizan datos históricos recopilados durante inspecciones rutinarias o extraordinarias realizadas por humanos con conocimientos especializados. Los elementos que utilizan este método de adquisición constituyen un pequeño porcentaje del número total de elementos (4.6%), y todos ellos involucran personal

calificado para realizar las inspecciones y recopilar los datos con los que se crearán los modelos de predicción.

3.5. PROCESAMIENTO DE LA INFORMACIÓN

En cuanto al procesamiento de la información, podemos observar que 20 de los 108 artículos analizados combinan varias técnicas o proponen nuevas para obtener características y preprocesar los datos con el fin de mejorar los resultados de las predicciones. Esto representa el 18.5% del número total de artículos.

Del restante 81.5%, solo dos de ellos proponen específicamente el uso de datos sin procesar para evitar la alta carga computacional del preprocesamiento [9] - [10].

3.6. MÉTODOS DE APRENDIZAJE AUTOMÁTICO EN MANTENIMIENTO PREDICTIVO

Entre todos los artículos, podemos diferenciar entre aquellos que utilizan métodos de "aprendizaje profundo" y redes neuronales de aquellos que utilizan arquitecturas más tradicionales de "aprendizaje automático". Para identificar mejor las diferencias entre estos, vamos a crear dos tablas, no solo diferenciando entre ellos, sino también entre los mecanismos o algoritmos utilizados.

En la Tabla 4, podemos ver una distribución de los diferentes algoritmos y capas utilizados en los artículos en los que se proponen modelos basados en redes neuronales.

En la Tabla 5, podemos observar la distribución de algoritmos de aprendizaje automático utilizados.

4. DISCUSIÓN

El objetivo de esta revisión ha sido recopilar, estudiar y sintetizar toda la literatura desde 2017 que utiliza mecanismos de Aprendizaje Automático en el campo del mantenimiento predictivo. Hemos tratado de destacar la tipología de datos utilizada para los modelos predictivos de Mantenimiento Predictivo (sensores, método de adquisición, fenómeno a estudiar) en la sección 3.4, así como el tratamiento dado a los datos (transformaciones, preprocesamiento mediante técnicas basadas en datos, uso de datos sin procesar en sistemas de aprendizaje profundo) en la sección 3.5. Finalmente, se realiza una comparación de los diversos algoritmos utilizados en esta literatura en la sección 3.6.

Para abordar los resultados, responderemos explícitamente a cada una de las preguntas de investigación propuestas al principio de este artículo.

4.1. FUENTES DE INFORMACIÓN EN MANTENIMIENTO PREDICTIVO

Como hemos podido observar, la literatura actual se caracteriza por el amplio uso de fuentes de datos abiertas, como el repositorio de degradación de motores turbofán, que ofrece resultados de simulación en C-MAPSS, ofrecido por el PCoE de la NASA.

La mayoría de los artículos que utilizan el repositorio de degradación de motores turbofán como fuente de datos tienen como

Mecanismo de Aprendizaje Profundo	Referencias
ANN	23
LSTM	10
CNN	6
O-RBM	1
1-FCLCNN	1
FCN	1
ResNet	1
ESN	1
ESN basada en GOA	1
DBN	1
OS-ELM basada en C-DBN	1

Tabla 4. Mecanismos de aprendizaje profundo utilizados en los artículos.

Mecanismo de Aprendizaje Automático	Referencias
SVM	16
Random Forest	13
Decision Tree	8
Linear Regression	5
Naive Bayes	4
SVR	3
KNN	3
XGBoost	3
Decision Forest	3
Gradient Boost	2
LVO	2
K-Means Clustering	2
Symbolic Regression	2
Boosted Decision Tree	1
DBN	1
BLR	1
Bootstrap Aggregation	1
MLE + CCF	1
Discriminant Analysis	1

Tabla 5. Mecanismos de aprendizaje automático utilizados en los artículos.

objetivo demostrar la eficiencia de nuevos algoritmos y arquitecturas en relación con las lecturas genéricas de sensores.

Este conjunto de datos contiene un conjunto de medidas sin etiquetar de diferentes sensores en diferentes partes del motor turbofán, por lo que no podemos asociar la fuente de datos a una escala o medida física específica, lo que lleva a modelos de predicción puramente basados en datos.

Para el resto de los temas de estudio enumerados en la Tabla 3, observamos que para 39 de ellos (61.90%), se han utilizado combinaciones de varias magnitudes físicas o no se indica directamente la naturaleza de la medida para realizar las predicciones, concretamente en: aerogeneradores, rieles, maquinaria rotativa, carreteras, buques de transporte, automóviles, instalaciones de HVAC, intercambiadores de calor, herramientas de corte de metal, acondicionadores de aire interiores, herramientas de corte por chorro de agua, adsorbedores, bobinas calefactoras, ventiladores radiales y APS.

Dentro de los fenómenos físicos más comúnmente utilizados de forma aislada para calcular la vida útil de la maquinaria se encuentra la **vibración**, utilizada en 7 de los 29 temas de estudio y en un total de 9 elementos. Esto no es infrecuente: desde 1974 ha habido normas, como la ISO 2372, sobre la medición y evaluación del nivel de vibración aceptable en función del tamaño de la maquinaria, siendo la más actual la ISO 20816 de 2016. Esta última norma incluye la evaluación de la vibración no solo en máquinas rotativas, sino en cualquier parte, rotativa o no, de una máquina completa.

La existencia de la norma ISO 20816 no solo facilita la adquisición de información relacionada con la vibración, sino que también establece líneas de trabajo que permiten la transformación de una serie de variables continuas, como la cantidad de vibración, las dimensiones de la máquina y la dureza del soporte, en variables categóricas como la severidad de la vibración, que se pueden categorizar como buena, satisfactoria, insatisfactoria e inaceptable.

Por lo tanto, para responder a la primera pregunta (Q1) **¿qué fuentes de información se utilizan comúnmente en el mantenimiento predictivo?**, podemos decir que dentro de la literatura actual lo que más abunda es el **uso de una combinación de sensores sin tener en cuenta las cantidades físicas medidas al realizar las predicciones**, ya sea la fuente de datos sintéticos, como C-MAPSS, o una aplicación a un conjunto de datos reales.

Además, encontramos que la **vibración es la magnitud física más utilizada de forma aislada**, es decir, sin estar en combinación con otras magnitudes físicas, y que dentro de los artículos, estos

		Machine				
		Class I small machines	Class II medium machines	Class III large rigid foundation	Class IV large soft foundation	
Vibration Velocity Vms	in/s	mm/s				
	0,01	0,28	GOOD			
	0,02	0,45				
	0,03	0,71				
	0,04	1,12	SATISFACTORY			
	0,07	1,80				
	0,11	2,80	UNSATISFACTORY			
	0,18	4,50				
	0,28	7,10	UNACCEPTABLE			
	0,44	11,20				
0,70	18,00					
0,71	28,00					
1,10	45,00					

VIBRATION SEVERITY PER ISO 10816

Figura 3. Severidad de la vibración acorde a la ISO 2372 (10816).

aprovechan la antigua estandarización de la severidad de la vibración, como se puede ver en la Figura 3, para las mediciones y el preprocesamiento de datos [11].

4.2. PROCESAMIENTO DE DATOS EN MANTENIMIENTO PREDICTIVO

En cuanto al tratamiento de la información, podemos observar que no existe un criterio específico al realizar la fase de ingeniería de características, aunque es cierto que la gran mayoría realiza un preprocesamiento de los datos antes de proporcionarlos al modelo para su entrenamiento.

Entre las técnicas más innovadoras y con mejores resultados, destaca la presentada por [12], donde se aprovechan las ventajas de la computación paralela para la extracción de características espacio-temporales, que luego servirán como entrada a una red neuronal convolucional unidimensional.

En la comparación de rendimiento entre el modelo al que se aplica el preprocesamiento mencionado anteriormente y el que solo utiliza la red CNN, se observa una diferencia de rendimiento bastante alta teniendo en cuenta la desviación típica de la raíz media (RMSE), que es una buena medida de precisión para comparar los errores de predicción de diferentes modelos.

Otra de las técnicas más novedosas en términos de procesamiento de datos es el Multi-Loss Encoder with Convolutional Composite Features (MLE+CCF) propuesto por [13], donde se utiliza MLE para extraer características que luego sirven como entrada a la red neuronal artificial.

En la Tabla 6, el modelo propuesto por Peng et al. [12] demuestra una métrica RMSE un 35% menor que el modelo CNN para el conjunto de datos FD001 y un 35,5% menor RMSE para el conjunto de datos FD003. Por otro lado, aunque la propuesta de Pillai et al. [13] muestra resultados prometedores, aún no supera al modelo mencionado anteriormente.

Además, también debemos tener en cuenta las transformaciones categóricas estandarizadas, como la realizada por Aqueveque et al. siguiendo la norma ISO 2372 [11], así como aquellas que aprovechan el conocimiento especializado de expertos para llevar a cabo transformaciones e interpretaciones de los datos [14], como parte del procesamiento de la información.

Aunque estos dos últimos artículos no utilizan el mismo conjunto de datos, por lo que no es apropiada una comparación directa, el artículo de Aqueveque realiza predicciones con una precisión más que aceptable (alrededor del 95%) en las predicciones de la severidad vibratoria, mientras que el artículo de Ruiz-Sarmiento

	FD001	FD003
CNN	17.22	15.50
1-FCLCNN-LSTM	11.17	9.99
MLE+CCF	11.57	11.83

Tabla 6. RMSE de las predicciones de diferentes modelos con conjuntos de datos del Repositorio de Datos de Prognosis de la NASA.

muestra un rendimiento (basado en el RMSE) de 0,59 en la predicción del estado de degradación después de cuatro secuencias de entrenamiento utilizando esta entrada del conocimiento de expertos en la fase de procesamiento de la información.

Finalmente, como respuesta a la pregunta de investigación (Q2) **¿cómo se trata la información en el mantenimiento predictivo?**, notamos la presencia de *propuestas novedosas* en la literatura cuando se trata de procesamiento de datos puramente impulsado por datos, especialmente cuando se trata de información de sensores cuyas fuentes de información están mezcladas y/o de diferentes cantidades físicas, pero también se introducen nuevas propuestas como el uso de normas de validación de medidas o *aprovechar el conocimiento de expertos* para realizar flujos de extracción de características y preprocesamiento.

4.3. MÉTODOS DE APRENDIZAJE AUTOMÁTICO EN MANTENIMIENTO PREDICTIVO

En cuanto al uso de algoritmos y técnicas de aprendizaje automático, podemos ver claramente que antes de 2020 la tendencia general iba hacia el uso de algoritmos de regresión (principalmente SVM) y modelos de decisión basados en árboles (Random Forest, Árboles de Decisión, Gradient Boost, Decision Forest), mientras que en 2020 y a lo largo de 2021, predominan las publicaciones que utilizan mecanismos de aprendizaje profundo como ANN y RNN.

Este cambio se ve principalmente potenciado por el hecho de que, al comparar modelos de aprendizaje automático utilizando un conjunto de datos común, generalmente los basados en redes neuronales funcionan mejor. Además, las redes LSTM son adecuadas para la clasificación, procesamiento y predicciones utilizando datos de series temporales [15].

En la Tabla 7, podemos observar una comparación del rendimiento de varios modelos para un conjunto de datos sintético basado en las métricas MSE, MSE normalizado, MAE y R².

Por lo tanto, basándonos en el trabajo de Bogojeski et al. [16], podemos decir que, según los resultados de referencia frente a su conjunto de datos de prueba, el modelo Long Short Term Memory (LSTM) es el que presenta el mejor comportamiento en comparación con el resto de los modelos en cuanto al rendimiento basado en la precisión de las predicciones.

Por otro lado, en el trabajo de Chen et al. [17] se realiza una comparación de rendimiento entre varios modelos utilizando las métricas MCC y RMSE, que se pueden observar en la Tabla 8.

La métrica MCC, descrita matemáticamente en el apéndice A, se representa comúnmente como *C* y se puede interpretar [18] teniendo en cuenta que una correlación de:

- *C* = 1, cuando las predicciones son perfectas,
- *C* = 0, cuando las predicciones no son mejores que aleatorias,
- *C* = -1, cuando hay un desacuerdo total entre la predicción y la observación

Así, podemos ver que, aunque el tiempo de entrenamiento de LSTM es más largo que en el resto de los modelos, logra el valor más alto de MCC, con un valor de 0.8248 y el valor más bajo de RMSE, que es de 379.8 días. Por otro lado, SVM muestra el peor rendimiento en este escenario, con un RMSE de 432.4 días y un MCC de 0.7738.

	MSE	MSE Normalizado	MAE	R ²
LRR	2.307	0.086	1.014	0.916
KRR	1.635	0.059	0.745	0.941
FFNN	1.496	0.054	0.672	0.946
ESN	0.256	0.009	0.173	0.991
LSTM	0.086	0.003	0.097	0.997

Tabla 7. Métricas de rendimiento de regresión en el conjunto de datos de prueba de Bogojeski et al. [16] para diferentes modelos.

Por lo tanto, para responder a la pregunta de investigación (Q3) **¿qué tipo de métodos de aprendizaje automático se utilizan en el mantenimiento predictivo?**; basándonos en la literatura y utilizando estas comparaciones previas como ejemplo, aunque no podemos afirmar categóricamente que los modelos del tipo LSTM siempre darán los mejores resultados, podemos decir que los *modelos basados en redes neuronales artificiales tienen un mejor rendimiento* en las predicciones orientadas al mantenimiento predictivo que aquellos basados en algoritmos de regresión más simples, como la Regresión Lineal de Ridge (LRR) o SVM.

No exclusivamente centrado en el algoritmo, también podemos identificar que tres de los artículos hacen uso del **Aprendizaje por Transferencia** debido a la escasez de datos fiables y como enfoque para reducir la necesidad de ejemplos etiquetados [19]- [20]- [21].

El aprendizaje por transferencia es un problema de investigación en el aprendizaje automático que se centra en almacenar el conocimiento adquirido al resolver un problema y aplicarlo a un problema diferente pero relacionado. El artículo de Gribbestad et al. [19] pone en valor este enfoque para el Mantenimiento Predictivo y sugiere el Aprendizaje por Transferencia como un campo de investigación prometedor para pronósticos fiables.

5. CONCLUSIONES

Se ha realizado una revisión de la actualidad en el campo académico del aprendizaje automático y el aprendizaje profundo en el mantenimiento predictivo. Se ha llevado a cabo una revisión bibliográfica de los últimos cinco años, basada en aquellos artículos que abordan la información sobre las fuentes de datos utilizadas para el mantenimiento predictivo, el tratamiento dado a dichos datos y los métodos o técnicas utilizados. La revisión ha mostrado que existen diferentes fuentes de información utilizadas, que pueden clasificarse como datos abiertos conjuntos, datos históricos de sensores, datos históricos de inspecciones y datos en tiempo real. Asimismo, se ha observado que el procesamiento de datos no solo utiliza técnicas tradicionales de preprocesamiento, sino que aproximadamente una quinta parte de los artículos propone nuevas herramientas. Se ha utilizado una amplia variedad de técnicas y algoritmos en Aprendizaje Profundo, siendo la Red Neuronal Artificial (ANN) la más utilizada, y en Aprendizaje Automático, con SVM siendo el algoritmo más utilizado, seguido de cerca por Random Forest.

5.1. LIMITACIONES

Aunque tanto **Scopus** como **Web of Science** se utilizaron en la investigación inicial sobre revisiones previas que cubrirían nuestras preguntas de investigación, durante el proceso de revisión solo se utilizó una base de datos (el índice **SCIE** de **Web of Science**). Si bien somos conscientes de que esto limita la revisión al no incluir algunos resultados únicos que podrían encontrarse en otras fuentes,

	LSTM	RNN	FCNN	DCNN	SVM
Media MCC	0.8248	0.8221	0.8240	0.8240	0.7738
Media RMSE (días)	379.8	382.1	387.2	387.2	432.4
Tiempo de entrenamiento (s)	259.2	107.5	34.65	43.15	7.263

Tabla 8. Métricas de rendimiento de varios modelos para un conjunto de datos del mundo real de una empresa de flotas del Reino Unido con codificación one-hot del trabajo de Chen et al. [17]

consideramos que el número resultante de artículos cubiertos es suficiente para obtener una imagen de la literatura actual y proporcionar respuestas informadas a nuestras preguntas de investigación, dadas las características del índice mencionado anteriormente.

5.2. TRABAJO FUTURO

Como se mencionó en los objetivos, este artículo tiene como objetivo servir como base para futuras investigaciones en la creación de un marco confiable para la industria en lo que respecta al uso de técnicas de aprendizaje automático para el mantenimiento predictivo.

En alineación con eso, a partir de los resultados presentados en este artículo, surgen preguntas adicionales como: *¿cuál podría ser la integración del conocimiento humano en un proceso de mantenimiento predictivo?* o *¿qué proceso de selección e instalación de sensores se debe tener en cuenta para recopilar los datos?*

Las respuestas a estas preguntas ayudarán en la definición y aplicación del marco mencionado anteriormente.

REFERENCIAS

- [1] D. A. Institute, Predictive Maintenance - Position Paper, 2017.
- [2] Y. Lei, B. Yang, X. Jiang, F. Jia, N. Li and A. K. Nandi, "Applications of machine learning to machine fault diagnosis: A review and roadmap," *Mechanical Systems and Signal Processing*, vol. 138, p. 106587, 2020.
- [3] N. M. Thoppil, V. Vasu and C. S. P. Rao, "Deep Learning Algorithms for Machinery Health Prognostics Using Time-Series Data: A Review," *Journal Of Vibration Engineering & Technologies*, 2021.
- [4] N. Valceschini, M. Mazzoleni and F. Previdi, "Inertial load classification of low-cost electro-mechanical systems under dataset shift with fast end of line testing," *Engineering Applications of Artificial Intelligence*, vol. 105, p. 104446, 2021.
- [5] A. Luque, M. Mazzoleni, A. Carrasco and A. Ferramosca, "Visualizing Classification Results: Confusion Star and Confusion Gear," *IEEE Access*, vol. 10, p. 1659-1677, 2022.
- [6] M. Mazzoleni, G. Di Rito and F. Previdi, *Electro-Mechanical Actuators for the More Electric Aircraft*, Springer, 2021.
- [7] F. E. de Abreu Melo Junior, E. P. de Moura, P. A. Costa Rocha and C. F. de Andrade, "Unbalance evaluation of a scaled wind turbine under different rotational regimes via detrended fluctuation analysis of vibration signals combined with pattern recognition techniques," *Energy*, vol. 171, p. 556-565, 2019.
- [8] S. Schwendemann, Z. Amjad and A. Sikora, "A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines," *Computers In Industry*, vol. 125, 2021.
- [9] C. Yang, Y. Sun, C. Ladubec and Y. Liu, "Developing Machine Learning-Based Models for Railway Inspection," *Applied Sciences-basel*, vol. 11, 2021.
- [10] W. Zhang, D. Yang and H. Wang, "Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey," *Ieee Systems Journal*, vol. 13, p. 2213-2227, 2019.
- [11] P. Aqueveque, L. Radrigan, F. Pastene, A. S. Morales and E. Guerra, "Data-Driven Condition Monitoring of Mining Mobile Machinery in Non-Stationary Operations Using Wireless Accelerometer Sensor Modules," *Ieee Access*, vol. 9, p. 17365-17381, 2021.
- [12] C. Peng, Y. Chen, Q. Chen, Z. Tang, L. Li and W. Gui, "A Remaining Useful Life Prognosis of Turbofan Engine Using Temporal and Spatial Feature Fusion," *Sensors*, vol. 21, 2021.
- [13] S. Pillai and P. Vadakkepat, "Two stage deep learning for prognostics using multi-loss encoder and convolutional composite features," *Expert Systems With Applications*, vol. 171, 2021.
- [14] J.-R. Ruiz-Sarmiento, J. Monroy, F.-A. Moreno, C. Galindo, J.-M. Bonelo and J. Gonzalez-Jimenez, "A predictive model for the maintenance of industrial machinery in the context of industry 4.0," *Engineering Applications Of Artificial Intelligence*, vol. 87, 2020.
- [15] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, p. 1735-1780, 1997.
- [16] M. Bogojeski, S. Sauer, F. Horn and K.-R. Mueller, "Forecasting industrial aging processes with machine learning methods," *Computers Et Chemical Engineering*, vol. 144, 2021.
- [17] C. Chen, Y. Liu, S. Wang, X. Sun, C. Di Cairano-Gilfedder, S. Titmus and A. A. Syntetos, "Predictive maintenance using cox proportional hazard deep learning," *Advanced Engineering Informatics*, vol. 44, 2020.
- [18] B. W. Matthews, "Comparison of the predicted and observed secondary structure of T4 phage lysozyme," *Biochimica et Biophysica Acta (BBA) - Protein Structure*, vol. 405, p. 442-451, 1975.
- [19] M. Gribbestad, M. U. Hassan and I. A. Hameed, "Transfer Learning for Prognostics and Health Management (PHM) of Marine Air Compressors," *Journal Of Marine Science And Engineering*, vol. 9, 2021.
- [20] F.-K. Wang and T. Mamo, "Hybrid approach for remaining useful life prediction of ball bearings," *Quality And Reliability Engineering International*, vol. 35, p. 2494-2505, 2019.
- [21] H. Ding, R. X. Gao, A. J. Isaksson, R. G. Landers, T. Parisini and Y. Yuan, "State of AI-Based Monitoring in Smart Manufacturing and Introduction to Focused Section," *Ieee-asme Transactions On Mechatronics*, vol. 25, p. 2143-2154, 2020.

MATERIAL SUPLEMENTARIO

https://www.revistadyna.com/documentos/pdfs/_adic/10950-1_en.pdf

