



MÁSTER EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

Comparación de Comportamientos de Bombas de Agua de Circulación usando Herramientas de Machine Learning

Autor: Mencía Sánchez Rosillo

Director: Miguel Ángel Sanz Bobi

Madrid

Junio de 2025

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
Comparación de Comportamientos de Bombas de Agua de Circulación usando
Herramientas de Machine Learning

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2024/25 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido
tomada de otros documentos está debidamente referenciada.

Fdo.: Mencía Sánchez Rosillo

Fecha: 23/06/2025

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: Miguel Ángel Sanz Bobi

Fecha: 23/06/2025



MÁSTER EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

Comparación de Comportamientos de Bombas de Agua de Circulación usando Herramientas de Machine Learning

Autor: Mencía Sánchez Rosillo

Director: Miguel Ángel Sanz Bobi

Madrid

COMPARACIÓN DE COMPORTAMIENTOS DE BOMBAS DE AGUA DE CIRCULACIÓN USANDO HERRAMIENTAS DE MACHINE LEARNING

Autor: Sánchez Rosillo, Mencía.

Director: Sanz Bobi, Miguel Ángel.

Entidad Colaboradora: Endesa

RESUMEN DEL PROYECTO

Este trabajo aplica técnicas de aprendizaje automático, concretamente redes neuronales convolucionales (CNN) y LSTM, al análisis de datos industriales para evaluar el comportamiento de bombas de agua de circulación. Se desarrollan y comparan modelos predictivos capaces de identificar desviaciones operativas asociadas a fallos incipientes. La metodología permite extraer curvas de riesgo acumulado que se contrastan con eventos reales de mantenimiento, demostrando el valor de estas herramientas para anticipar intervenciones y mejorar la gestión predictiva de activos.

Palabras clave: mantenimiento predictivo, CNN, LSTM, bombas de agua de circulación, aprendizaje automático.

1. Introducción

El mantenimiento predictivo es capaz de anticipar fallos en sistemas industriales mediante el análisis de datos operativos, consiguiendo una mejora en la eficiencia y en la reducción de costes. Con el aumento de sensores en planta y el avance de las técnicas de aprendizaje automático, es posible desarrollar modelos que detecten desviaciones en el comportamiento de los equipos antes de que se produzcan fallos reales.

Este trabajo aplica redes neuronales CNN y LSTM al análisis de datos históricos de bombas de agua de circulación, comparando su rendimiento en la detección de anomalías. A partir de señales de operación reales, se evalúa su utilidad como herramienta de apoyo para la planificación del mantenimiento.

2. Definición del proyecto

El objetivo de este estudio es desarrollar e implementar un sistema de análisis basado en redes neuronales para detectar las anomalías en bombas de agua de circulación mediante la evaluación de variables eléctricas, térmicas e hidráulicas. Se entrenan modelos CNN y LSTM sobre datos históricos de operación y se comparan sus resultados en dos bombas físicamente equivalentes, pero con comportamientos operativos distintos.

A partir de las predicciones de los modelos, se generan curvas de desviación acumulada que permiten evaluar el riesgo de fallo y su correspondencia con eventos reales de mantenimiento. Esta metodología busca ofrecer una herramienta complementaria al diagnóstico tradicional, capaz de anticipar fallos, identificar cuál es el mejor modelo para cada caso y, con ello, mejorar la toma de decisiones en entornos industriales.

3. Descripción del modelo/sistema/herramienta

El sistema desarrollado se compone de varias etapas: adquisición y limpieza de datos, entrenamiento de modelos, evaluación de errores y análisis del riesgo acumulado. Se han utilizado redes neuronales convolucionales (CNN) y redes LSTM para predecir variables clave a partir de otras señales relacionadas, empleando una estructura de ventana temporal que capta la dinámica del sistema.

Cada modelo ha sido entrenado con datos históricos de 2020 para una bomba concreta, y luego evaluado sobre varios años. A partir de las desviaciones entre la predicción y el valor real, se calcula un indicador de estrés que permite visualizar el comportamiento del equipo a lo largo del tiempo. Este proceso se aplica de forma paralela a las dos bombas para garantizar la comparabilidad.




Ilustración 1 - Arquitectura comparativa del sistema de mantenimiento predictivo aplicado a bombas de circulación. Fuente: Elaboración propia.

4. Resultados

Los modelos desarrollados han permitido identificar desviaciones significativas entre las predicciones y los valores reales de las señales analizadas. Estas desviaciones, acumuladas en el tiempo, revelan patrones que en muchos casos se alinean con eventos de mantenimiento correctivo o preventivo registrados en planta.

Las curvas generadas muestran diferencias claras entre las dos bombas analizadas. En particular, se observan mayores niveles de desviación acumulada en los modelos aplicados a la bomba 2, lo que sugiere un comportamiento más irregular o degradado. Además, los modelos LSTM tienden a detectar cambios sostenidos en el tiempo,

mientras que los CNN reaccionan con mayor intensidad ante anomalías puntuales. Estas diferencias aportan valor al combinarlos como herramientas complementarias.

Variable	Modelo sensible	Recomendación principal
Caudal de descarga	CNN	Eventos bruscos
Intensidad fase R	LSTM	Cambios graduales
Intensidad fase S	LSTM	Monitoreo continuo
Intensidad fase T	LSTM	Síntomas lentos
Temp. fase R	CNN	Detección de picos térmicos
Temp. fase S	CNN	Aumentos localizados
Temp. fase T	CNN	Depende ubicación bomba
Cojinete radial CC21	LSTM	Seguimiento térmico sostenido
Cojinete radial CC22	LSTM	Anticipación térmica

Ilustración 2 – Tabla resumen de los resultados. Fuente: Elaboración propia.

5. Conclusiones

Los resultados obtenidos demuestran que el uso de redes neuronales para el análisis de señales industriales permite identificar patrones anómalos con capacidad anticipativa frente a fallos. Las curvas de desviación acumulada han mostrado correlación con varios eventos de mantenimiento, validando su utilidad como indicador de riesgo.

Además, la comparación entre dos bombas operativamente similares ha puesto de manifiesto diferencias relevantes en su comportamiento, incluso bajo condiciones de entrenamiento idénticas, lo que refuerza el valor de este enfoque para caracterizar el estado individual de cada equipo. En conjunto, el sistema propuesto representa una herramienta eficaz para apoyar decisiones de mantenimiento predictivo en entornos industriales complejos.

6. Referencias

- [1] 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*, 495, 012067. <https://doi.org/10.1088/1757-899X/495/1/012067>
- [2] Silva, W., & Capretz, M. (2019). Assets predictive maintenance using convolutional neural networks. In *SNPD 2019 – 20th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing* (pp. 59–66). IEEE. <https://doi.org/10.1109/SNPD.2019.8935752>
- [3] De Vita, F., & Bruneo, D. (2019). On the use of LSTM networks for predictive maintenance in smart industries. In *2019 IEEE International Conference on Smart Computing (SMARTCOMP)* (pp. 241–248). IEEE. <https://doi.org/10.1109/SMARTCOMP.2019.00059>
- [4] Nasser, A., & Al-Khazraji, H. (2022). A hybrid of convolutional neural network and long short-term memory network approach to predictive maintenance. *International Journal of Electrical and Computer Engineering*, 12(1), 721–730. <https://doi.org/10.11591/ijece.v12i1.pp721-730>
- [5] Olesen, J. F., & Shaker, H. R. (2020). Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges. *Sensors*, 20(8), 2425. <https://doi.org/10.3390/s20082425>

COMPARISON OF CIRCULATING WATER PUMP BEHAVIORS USING MACHINE LEARNING TOOLS

Author: Sánchez Rosillo, Mencía.

Supervisor: Sanz Bobi, Miguel Ángel.

Collaborating Entity: Endesa

ABSTRACT

This study employs machine learning techniques, specifically convolutional neural networks (CNNs) and long short-term memory (LSTM) networks, to analyze industrial data and evaluate the behavior of water circulation pumps. Predictive models are developed and compared to identify operational deviations associated with incipient failures. The methodology enables the extraction of accumulated risk curves, which are contrasted with actual maintenance events, demonstrating the value of these tools in anticipating interventions and improving predictive asset management.

Keywords: predictive maintenance, CNN, LSTM, water circulation pumps, machine learning.

1. Introduction

Predictive maintenance enables the anticipation of failures in industrial systems by analyzing operational data, improving efficiency, and reducing costs. With the growing availability of plant sensors and advancements in machine learning techniques, it is now possible to develop models capable of detecting deviations in equipment behavior before actual failures occur.

This work applies CNN and LSTM neural networks to the analysis of historical data from water circulation pumps, comparing their performance in anomaly detection. Based on real operational signals, their usefulness is evaluated as a decision-support tool for maintenance planning.

2. Project Definition

The objective of this study is to develop and implement an analysis system based on neural networks to detect anomalies in water circulation pumps by evaluating electrical, thermal, and hydraulic variables. CNN and LSTM models are trained based on historical operational data, and their results are compared using two physically equivalent pumps with different operational behaviors.

Based on the model predictions, accumulated deviation curves are generated to evaluate the risk of failure and its correlation with actual maintenance events. This methodology aims to offer a complementary tool to traditional diagnostics, capable of anticipating failures, identifying the best-performing model in each case, and ultimately enhancing decision-making in industrial environments.

3. Model/System/Tool Description

The developed system consists of several stages: data acquisition and cleaning, model training, error evaluation, and accumulated risk analysis. Convolutional neural networks (CNN) and LSTM networks were used to predict key variables based on related signals, using a temporal window structure that captures the system's dynamics.

Each model was trained using historical data from 2020 for a specific pump and then evaluated over multiple years. From the deviations between predicted and actual values, a stress indicator is calculated, which allows visualization of the equipment's behavior over time. This process is applied in parallel to both pumps to ensure comparability.




Illustration 3 - Comparative architecture of the predictive maintenance system applied to circulation pumps.

Source: Own elaboration.

4. Results

The developed models have made it possible to identify significant deviations between the predictions and the actual values of the analyzed signals. These deviations, when accumulated over time, reveal patterns that, in many cases, align with recorded corrective or preventive maintenance events.

The generated curves show clear differences between the two analyzed pumps. In particular, higher levels of accumulated deviation were observed in the models applied to Pump 2, suggesting more irregular or degraded behavior. Furthermore, the LSTM models tend to detect sustained changes over time, while CNN models respond more intensely to sudden anomalies. These differences provide added value when combining both as complementary tools.

Variable	Most Sensitive Model	Main Recommendation
Discharge flow rate	CNN	Abrupt event detection
Phase R current	LSTM	Gradual change detection
Phase S current	LSTM	Continuous monitoring
Phase T current	LSTM	Slow symptom detection
Phase R temperature	CNN	Thermal peak detection
Phase S temperature	CNN	Localized rise detection
Phase T temperature	CNN	Depends on pump location
Radial bearing temp. (CC21)	LSTM	Thermal condition tracking
Radial bearing temp. (CC22)	LSTM	Early thermal anticipation

Illustration 4 - Summary table of results. Source: Own elaboration.

5. Conclusions

The results obtained demonstrate that the use of neural networks for industrial signal analysis enables the identification of anomalous patterns with predictive capabilities regarding potential failures. The accumulated deviation curves have shown correlation with several maintenance events, validating their usefulness as risk indicators.

Moreover, the comparison between two operationally similar pumps has revealed significant differences in their behavior, even under identical training conditions. This highlights the value of the approach in characterizing the individual condition of each asset. Overall, the proposed system represents an effective tool to support predictive maintenance decision-making in complex industrial environments.

6. References

- [1] 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*, 495, 012067. <https://doi.org/10.1088/1757-899X/495/1/012067>
- [2] Silva, W., & Capretz, M. (2019). Assets predictive maintenance using convolutional neural networks. In *SNPD 2019 – 20th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing* (pp. 59–66). IEEE. <https://doi.org/10.1109/SNPD.2019.8935752>
- [3] De Vita, F., & Bruneo, D. (2019). On the use of LSTM networks for predictive maintenance in smart industries. In *2019 IEEE International Conference on Smart Computing (SMARTCOMP)* (pp. 241–248). IEEE. <https://doi.org/10.1109/SMARTCOMP.2019.00059>
- [4] Nasser, A., & Al-Khazraji, H. (2022). A hybrid of convolutional neural network and long short-term memory network approach to predictive maintenance. *International Journal of Electrical and Computer Engineering*, 12(1), 721–730. <https://doi.org/10.11591/ijece.v12i1.pp721-730>
- [5] Olesen, J. F., & Shaker, H. R. (2020). Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges. *Sensors*, 20(8), 2425. <https://doi.org/10.3390/s20082425>

Índice de la memoria

Capítulo 1. Introducción	7
Capítulo 2. Descripción de las Tecnologías.....	9
2.1 Sistemas de Agua de Circulación	9
2.2 Mantenimiento Predictivo y Curvas de Riesgo	12
2.3 Machine Learning y Deep Learning	12
2.3.1 Redes Neuronales Convolucionales (CNN).....	12
2.3.2 Redes LSTM.....	14
Capítulo 3. Estado de la Cuestión	17
3.1 Mantenimiento predictivo en sistemas industriales.....	17
3.2 Metodologías de Machine Learning aplicadas al PdM	18
3.2.1 Algoritmos supervisados tradicionales (árboles de decisión, Random Forest, y SVM). 19	
3.2.2 Redes neuronales y aprendizaje profundo (CNN, LSTM, autoencoders).....	21
3.2.3 Enfoques híbridos y modelos avanzados (gemelos digitales, combinaciones).....	23
3.2.4 Comparación de enfoques y resultados.....	25
3.3 Contribución y brechas identificadas	28
Capítulo 4. Definición del Trabajo	30
4.1 Justificación.....	30
4.2 Objetivos	31
4.3 Metodología.....	32
4.4 Planificación y Estimación Económica	34
Capítulo 5. Sistema/Modelo Desarrollado.....	37
5.1 Análisis del Sistema	37
5.2 Gestión de Señales y Variables	38
5.3 Estructura Técnica del Sistema	40
5.4 Implementación de modelos.....	45
5.4.1 Modelos CNN	45
5.4.2 Modelos LSTM.....	47
5.4.3 Extracción de errores y eventos anómalos.....	50

5.4.4 Escalabilidad y replicación.....	52
Capítulo 6. Análisis de Resultados.....	53
6.1 Gráficas de error: Bomba 1	53
6.1.1 Modelos CNN	53
6.1.2 Modelos LSTM.....	58
6.2 Gráficas de error: Bomba 2	65
6.2.1 Modelos CNN	65
6.2.2 Modelos LSTM.....	71
6.3 Gráficas de Comparación de la Desviación Acumulada:	78
Capítulo 7. Conclusiones y Trabajos Futuros.....	89
Capítulo 8. Alineación del Trabajo con los ODS	91
Capítulo 9. Bibliografía.....	94
ANEXO I:	97

Índice de figuras

Figura 1. Esquema funcional de una bomba de agua de circulación en operación. Fuente: Elaboración propia.....	10
Figura 2. Arquitectura CNN. Fuente: [17]	13
Figura 3. Esquema célula LSTM. Fuente: [18]	15
Figura 4. Fases de la metodología. Fuente: Elaboración propia.....	34
Figura 5. Gantt Chart. Fuente: Elaboración propia.	35
Figura 6. Estructura de carpetas y archivos del sistema de análisis predictivo implementado. Fuente: Elaboración propia.....	41
Figura 7. Estructura de archivos de datos históricos y scripts de preprocesamiento de datos para entrenamiento de modelos. Fuente: Elaboración propia.....	42
Figura 8. Organización de modelos, historiales y archivos de error para la Bomba 1 (Similar para la Bomba 2). Fuente: Elaboración propia.	43
Figura 9. Contenido del repositorio de análisis predictivo para Bomba 1 y Bomba 2. Fuente: Elaboración propia.....	45
Figura 10. Desviación del modelo CNN aplicado a la variable de caudal de descarga de la Bomba 1 en distintos años. Fuente: Elaboración propia.	54
Figura 11. Desviaciones del modelo CNN para intensidades eléctricas en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.....	55
Figura 12. Desviaciones del modelo CNN para temperaturas del motor en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.....	57
Figura 13. Desviaciones del modelo CNN para temperaturas de cojinete de la Bomba 1 (2020–2023). Fuente: Elaboración propia.	58
Figura 14. Desviación del modelo LSTM para caudal de descarga por año (2020–2023) de la Bomba 1. Fuente: Elaboración propia.	59
Figura 15. Desviaciones del modelo LSTM para intensidades eléctricas en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.....	61
Figura 16. Desviaciones del modelo CNN para temperatura del motor en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.....	63

Figura 17. Desviaciones del modelo LSTM para temperaturas de cojinete de la Bomba 1 (2020–2023). Fuente: Elaboración propia.	65
Figura 18. Desviación del modelo CNN para caudal de descarga por año (2020–2023) de la Bomba 2. Fuente: Elaboración propia.	65
Figura 19. Desviaciones del modelo CNN para intensidades eléctricas en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.....	68
Figura 20. Desviaciones del modelo CNN para temperatura del motor en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.....	70
Figura 21. Desviaciones del modelo CNN para temperaturas del cojinete de la Bomba 2 (2020–2023). Fuente: Elaboración propia.	71
Figura 22. Desviación del modelo LSTM para caudal de descarga por año (2020–2023) de la Bomba 2. Fuente: Elaboración propia.	72
Figura 23. Desviaciones del modelo LSTM para intensidades eléctricas en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.....	74
Figura 24. Desviaciones del modelo LSTM para temperaturas del motor en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.....	76
Figura 25. Desviaciones del modelo LSTM para temperaturas del cojinete de la Bomba 2 (2020–2023). Fuente: Elaboración propia.	77
Figura 26. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Caudal de descarga. Fuente: Elaboración propia.....	80
Figura 27. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase R. Fuente: Elaboración propia.	81
Figura 28. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase S. Fuente: Elaboración propia.	82
Figura 29. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase T. Fuente: Elaboración propia.	83
Figura 30. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase R. Fuente: Elaboración propia.....	83
Figura 31. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase S. Fuente: Elaboración propia.	84

Figura 32. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase T. Fuente: Elaboración propia.....	85
Figura 33. Comparación de la desviación acumulada resultante de CNN vs LSTM para las variables Temperatura del Cojinete. Fuente: Elaboración propia.	85
Figura 34. Objetivos de desarrollo sostenible. Fuente: Organización de las Naciones Unidas [25].	91

Índice de tablas

Tabla 1. Comparación de métodos de ML. Fuente: Benavente Álvarez [15]	20
Tabla 2. Comparativa de estudios representativos de PdM con machine learning en bombas de agua y sistemas afines. Fuente: Elaboración propia.	26
Tabla 3. Resumen variables empleadas en los modelos de predicción. Fuente: Elaboración propia.	40
Tabla 4. Tabla resumen de los resultados. Fuente: Elaboración propia.	88

Capítulo 1. INTRODUCCIÓN

Actualmente, en la industria energética, la fiabilidad y eficiencia operativa de los equipos críticos son factores cruciales para garantizar una producción segura, sostenible y que sea económicamente viable. Uno de los elementos más significativos en las centrales de generación, especialmente en los ciclos combinados, son las bombas de agua de circulación. Estas bombas tienen un papel clave en la evacuación del calor residual del ciclo termodinámico, manteniendo la temperatura del sistema dentro de sus márgenes operativos y, por tanto, preservando la eficacia global del proceso. Por otro lado, debido a su funcionamiento continuo y a las condiciones exigentes a las que se enfrentan, estos equipos están expuestos a un mayor desgaste progresivo que puede resultar en fallos inesperados si no se detectan a tiempo.

Tradicionalmente, las estrategias empleadas de mantenimiento se han basado en modelos correctivos o preventivos, que no siempre son capaces de anticipar los fallos ni optimizar los recursos disponibles de manera eficiente. En estos últimos años, se ha avanzado notablemente en las tecnologías digitales, la disponibilidad creciente de datos operativos y en el desarrollo de nuevas técnicas de análisis, que han dado lugar a enfoques más avanzados como el mantenimiento predictivo. Esta estrategia busca anticipar el descubrimiento de los fallos incipientes mediante el análisis del comportamiento real del sistema, usando como apoyo herramientas de inteligencia artificial que permiten detectar desviaciones significativas antes de que ocurran estos fallos críticos.

De esta manera, el presente estudio se enmarca en la necesidad creciente de aplicar técnicas de aprendizaje automático y aprendizaje profundo en entornos industriales reales, con el objetivo de construir sistemas de monitorización que detecten anomalías y, también, aporten valor operativo en la toma de decisiones. El trabajo propone una metodología basada en la modelización del comportamiento normal de las bombas mediante redes neuronales CNN y LSTM, entrenadas sobre datos históricos de sensores. Estas redes permiten identificar, en

tiempo real, patrones anómalos o de deterioro progresivo a través de un análisis sistemático del error de predicción acumulado.

La motivación principal del trabajo surge de la oportunidad de combinar el conocimiento técnico del sistema físico con herramientas avanzadas de análisis de datos, en un entorno donde los fallos inesperados pueden tener implicaciones graves tanto económicas como operativas y de seguridad. Detectar un problema en una bomba de agua de circulación con suficiente antelación puede evitar una parada no programada centrar y resultar en una reducción de costes de intervención y una prolongación de la vida útil de los componentes. Además, este tipo de solución tiene un fuerte potencial de escalabilidad y replicabilidad en otras unidades o plantas industriales, lo que refuerza su impacto tanto tecnológico como económico.

En este estudio se pretende, por tanto, responder a una necesidad real del sector industrial, integrando tecnologías modernas de inteligencia artificial en sistemas de supervisión técnica. A través de una metodología validada sobre datos reales y equipos operativos, se ofrece una propuesta concreta para avanzar hacia una gestión del mantenimiento más inteligente, eficiente y proactiva.

Capítulo 2. DESCRIPCIÓN DE LAS TECNOLOGÍAS

En este capítulo se describen en detalle las tecnologías, metodologías, algoritmos y herramientas utilizadas a lo largo del desarrollo del presente trabajo, con el objetivo de facilitar la comprensión técnica del estudio realizado. La naturaleza del trabajo, centrado en la monitorización inteligente del estado de salud de bombas de agua de circulación mediante técnicas de aprendizaje automático y profundo, ha requerido múltiples disciplinas integradas, desde la ingeniería térmica y de mantenimiento, hasta la ciencia de datos y el aprendizaje automático avanzado.

2.1 SISTEMAS DE AGUA DE CIRCULACIÓN

Las bombas de agua de circulación tienen un papel crítico en las plantas de generación eléctrica, esto es debido a que su principal función es asegurar la evacuación del calor residual procedente del proceso de condensación del vapor en el ciclo termodinámico. Para ello, impulsan agua a temperatura ambiente, dulce o salada en contacto a través del condensador para enfriar el vapor que resulta de la turbina de un ciclo agua-vapor. Estas bombas están sometidas a condiciones exigentes de funcionamiento y su deterioro progresivo puede comprometer gravemente la eficiencia energética y operativa de la instalación. Por lo tanto, es prioritario establecer sistemas que permitan controlar su rendimiento y detectar los fallos incipientes antes de que estos se conviertan en problemas graves.

Las funciones específicas del sistema de agua de circulación incluyen:

- Refrigerar el condensador principal de la central.
- Mantener los tubos del condensador completamente inundados, garantizando una óptima transmisión de calor.
- Limpiar internamente los tubos mediante un sistema de esferas circulantes, que elimina incrustaciones por frotamiento.

- Impulsar el agua desde la toma marina hasta el mar, tras su paso por el condensador.
- Filtrar el agua de mar a lo largo del recorrido, evitando la entrada de sólidos en el sistema.

El filtrado del agua se realiza en varios puntos críticos: rejillas fijas y móviles a la entrada de las cántaras, filtros auto limpiantes en la entrada al condensador y captadores de esferas en la salida de este. Estas esferas, tras ser recogidas, son recirculadas mediante bombas específicas al punto de inyección para reiniciar el ciclo de limpieza.




Figura 1. Esquema funcional de una bomba de agua de circulación en operación. Fuente: Elaboración propia.

Las bombas de agua de circulación con las que se ha trabajado son bombas verticales de eje prolongado, con cierre mediante sello mecánico, acoplamiento flexible, y un diseño tipo non pull-out que refuerza su estanqueidad. Cada bomba ofrece una capacidad hidráulica de 11.433 m³/h y una altura dinámica total de 14 metros, operando con una sumergencia mínima de 2 metros. El conjunto hidráulico está construido con materiales resistentes a la corrosión: acero inoxidable A240 316L para el cuerpo y envolvente, A276 316L para el eje, y fundición A743 CF3M para el rodete. Estas bombas disponen de una campana de aspiración de 1450 mm de diámetro y un codo de impulsión con brida AWWA clase B de 42 pulgadas. La presión de diseño es de 3,5 barg en impulsión y -1 barg en aspiración. Además, los sellos y cojinetes se refrigeran con el propio caudal bombeado.

Cada bomba es accionada por un motor eléctrico trifásico ABB modelo HXR 500LM10, de 600 kW de potencia, con rotor tipo jaula de ardilla, alimentado a 6 kV y 50 Hz. La velocidad a plena carga es de 596 rpm. El motor presenta un grado de protección IP-55, lo que lo hace apto para condiciones de humedad y salinidad elevadas.

Es fundamental el funcionamiento fiable y continuo de las bombas para mantener el equilibrio térmico del ciclo combinado. Cualquier anomalía, como una caída en el caudal, vibraciones excesivas, pérdida de rendimiento hidráulico o sobrecalentamiento de los componentes, puede terminar en una reducción de potencia, pérdida de eficiencia o incluso paradas no programadas. Por ello, este estudio añade una metodología de mantenimiento predictivo que se basa en modelos de comportamiento normal y técnicas de aprendizaje automático que se explicarán posteriormente. Estas técnicas son capaces de detectar las desviaciones significativas en el comportamiento de la bomba antes de que se dé un fallo. De esta manera, se consigue una gestión más eficaz del mantenimiento basada en el estado real del equipo.

Para ser capaces de detectar de forma precisa el estado de salud de las bombas de agua de circulación, se necesita un seguimiento continuo de ciertas variables que describen su funcionamiento. Las variables seleccionadas en este estudio tienen una relación directa con el rendimiento térmico, hidráulico y eléctrico del sistema. Por un lado, están las temperaturas de los cojinetes, ya que un aumento anormal en estos valores suele ser un indicador temprano de problemas mecánicos, como fricción excesiva o desgaste interno. También se han considerado las temperaturas de las tres fases del motor eléctrico (fases R, S y T), que permiten detectar desequilibrios térmicos en el bobinado. Un sobrecalentamiento persistente en una o varias fases puede advertir sobre sobrecargas, desequilibrios de tensión o fallos en los aislamientos.

Por otro lado, el caudal de descarga es una medida clave del rendimiento hidráulico ya que, si el caudal sobrepasa los límites esperados, puede estar indicando obstrucciones, cavitación o una pérdida de eficiencia en el rodete. También se ha incluido la presión de descarga, que permite entender cómo está respondiendo la bomba a la carga hidráulica. Cambios en esta

presión pueden revelar desde desequilibrios en el sistema hasta fallos internos en la bomba. Finalmente, se han analizado las intensidades eléctricas de las tres fases del motor. Estas corrientes reflejan el esfuerzo eléctrico que realiza el motor para mantener la bomba en marcha, y variaciones anómalas de los valores de corriente entre fases o incrementos persistentes, pueden ser síntomas de sobrecargas o fallos en el bobinado.

2.2 MANTENIMIENTO PREDICTIVO Y CURVAS DE RIESGO

El mantenimiento predictivo es una estrategia que sirve para anticipar fallos en los equipos antes de que se produzcan, utilizando para ello el análisis continuo de datos operativos. A diferencia de los enfoques clásicos, como el mantenimiento correctivo (que actúa solo después de una avería) o el mantenimiento preventivo (que interviene según calendarios fijos), el mantenimiento predictivo toma decisiones basadas en el comportamiento real de los equipos. Esta forma de actuar permite realizar intervenciones únicamente cuando son necesarias, optimizando la disponibilidad de los activos, reduciendo costes y mejorando la fiabilidad global del sistema [14].

2.3 MACHINE LEARNING Y DEEP LEARNING

El uso de técnicas de aprendizaje automático y aprendizaje profundo ha sido una parte fundamental en el desarrollo del sistema de monitorización propuesto en este trabajo. El objetivo ha sido la construcción de unos modelos capaces de aprender el comportamiento normal de las variables asociadas al estado de las bombas de agua, detectar las desviaciones significativas y anticipar el deterioro progresivo antes de que ocurran los fallos. Para ello, dos tipos de arquitectura han sido empleadas: redes convolucionales (CNN) y redes recurrentes LSTM.

2.3.1 REDES NEURONALES CONVOLUCIONALES (CNN)

En primer lugar, las CNNs, tradicionalmente usadas en el sector de procesamiento de imágenes, han demostrado ser muy efectivas en el análisis de series temporales

multivariantes. En este estudio, las CNN se han aplicado principalmente a tareas de modelado de variables como la temperatura de los cojinetes o el caudal de descarga. Estas redes tienen la capacidad de extraer automáticamente patrones relevantes en los datos sin necesidad de realizar una selección manual de características. A través del uso de filtros (o kernels) que se desplazan sobre la secuencia de datos, las CNN capturan estructuras locales y tendencias que resultan difíciles de identificar mediante métodos clásicos.

A continuación, se muestra un esquema representativo de una arquitectura típica de red convolucional, donde se pueden observar las principales etapas del proceso de aprendizaje:




Figura 2. Arquitectura CNN. Fuente: [22]


Como se observa en la Figura 2, una CNN comienza con una entrada de datos, que como se muestra en la imagen y en aplicaciones clásicas suele ser una imagen, pero en este caso puede adaptarse a series temporales como señales de temperatura o intensidad eléctrica. Los primeros bloques aplican convoluciones junto con funciones de activación ReLU, que permiten extraer características locales. Más adelante, se aplican operaciones de reducción de dimensionalidad (pooling) para simplificar la representación sin perder información relevante. Este proceso se puede repetir varias veces, acumulando capas que aprenden representaciones progresivamente más abstractas de los datos. Finalmente, la salida de esta etapa se aplanan (flatten) y se conecta con una red neuronal completamente conectada (fully connected), que se encarga de realizar la predicción final. En tareas de clasificación, la red finaliza con una capa softmax, pero en este trabajo se adapta para producir una estimación continua del valor esperado de cada variable [22].

La ventaja principal de las CNN en este contexto es su capacidad para aprender relaciones complejas entre múltiples señales (por ejemplo, la combinación entre intensidad eléctrica y presión de impulsión para estimar el caudal), sin necesidad de supuestos previos sobre la forma de esas relaciones. Gracias a esta propiedad, han sido empleadas como modelos base para generar predicciones a corto plazo del valor esperado de las variables más representativas del sistema. Posteriormente, estas predicciones han sido comparadas con los valores reales, y la diferencia entre ambos ha servido como punto de partida para calcular el error de comportamiento del sistema.

2.3.2 REDES LSTM

Por otro lado, las redes LSTM son un tipo específico de redes neuronales recurrentes que se diseñan para trabajar con secuencias largas de datos. Su arquitectura incorpora mecanismos de memoria que permiten retener información relevante durante periodos prolongados de tiempo, lo que resulta especialmente útil en la modelización de fenómenos que presentan una evolución lenta pero progresiva, como es el caso del deterioro de una bomba de agua de circulación. A diferencia de otros tipos de redes, las LSTM tienen la capacidad de aprender dependencias de largo plazo sin sufrir el problema del desvanecimiento del gradiente, lo que las hace perfectas para la detección de cambios graduales en el comportamiento del sistema.

A continuación, se muestra un esquema representativo del funcionamiento interno de una célula LSTM, donde se pueden observar los distintos componentes responsables del control de la memoria y del flujo de información en la red:



LSTM
 (Long-Short Term Memory)

Figura 3. Esquema célula LSTM. Fuente: [23]

En la Figura 3, se aprecia una célula LSTM que contiene varias compuertas que regulan cómo se procesa y almacena la información a lo largo del tiempo. La entrada de la célula (x_t) se combina con el estado oculto anterior (h_{t-1}) y pasa por tres puertas principales. La primera, conocida como puerta de olvido (forget gate), decide qué parte de la memoria anterior (c_{t-1}) debe eliminarse, usando una función sigmoide (σ) que genera un valor entre 0 y 1. A continuación, la puerta de entrada (input gate) decide qué nueva información se almacenará, combinando una activación $\tanh$ con otra función sigmoide. La actualización de la memoria se realiza sumando la parte retenida de la memoria anterior con la nueva información seleccionada. Finalmente, la puerta de salida (output gate) regula qué parte de la memoria interna se usará para calcular el nuevo estado oculto (h_t), que será la salida de la célula en ese instante y servirá de entrada para el siguiente paso temporal. Esta estructura permite que la red "recuerde" o "olvide" información de manera controlada, lo cual es fundamental para identificar patrones temporales de larga duración en sistemas complejos [24].

En este estudio, las redes LSTM han sido empleadas para el análisis de la evolución temporal de las curvas de error acumulado, también llamadas curvas de estrés. Estas curvas reflejan la desviación entre el comportamiento esperado y el observado, y su pendiente permite evaluar si existe un deterioro y cuál es su ritmo. Con esta información, las LSTM pueden

estimar el tiempo restante hasta que la bomba requiera una intervención de mantenimiento, una métrica conocida como Remaining Useful Life (RUL). Esto resulta especialmente útil para priorizar tareas de mantenimiento y evitar intervenciones innecesarias o fallos inesperados [21][10].

Además, en investigaciones recientes como veremos más adelante se ha demostrado que la combinación de arquitecturas CNN y LSTM puede mejorar significativamente el rendimiento de los modelos en tareas de predicción sobre series temporales. Esta combinación permite que el modelo aproveche la capacidad de las CNN para extraer patrones espaciales y relaciones locales entre variables, y la capacidad de las LSTM para modelar cómo estos patrones evolucionan a lo largo del tiempo. Aunque en este trabajo se han explorado ambos tipos de redes por separado, la combinación CNN-LSTM representa una línea de trabajo con alto potencial para aplicaciones futuras, especialmente cuando se desea capturar tanto dinámicas rápidas como procesos lentos de deterioro en sistemas complejos [12].

En resumen, el uso de modelos de aprendizaje profundo ha permitido abordar de forma eficaz el reto de anticipar fallos en equipos industriales críticos, a partir del análisis de variables operativas. Estas técnicas han sido clave para la detección temprana de desviaciones y la evaluación del estado de salud de las bombas de agua de circulación, proporcionando una herramienta sólida para avanzar hacia una estrategia de mantenimiento predictivo basada en datos reales.

Capítulo 3. ESTADO DE LA CUESTIÓN

A lo largo de este capítulo se revisan los trabajos y soluciones existentes en el ámbito relacionado con el estudio. En este contexto, las plantas de ciclo combinado constituyen un entorno industrial altamente exigente en el que las bombas de agua de circulación son componentes esenciales para garantizar la refrigeración del sistema y mantener la eficiencia térmica. La evolución de las estrategias de mantenimiento de las bombas ha conducido al desarrollo del mantenimiento predictivo, una metodología centrada en anticipar los fallos mediante el análisis de datos operativos recogidos en tiempo real. Para realizar este trabajo es esencial entender los principales enfoques tecnológicos, avances recientes y retos asociados a la aplicación del mantenimiento predictivo.

3.1 *MANTENIMIENTO PREDICTIVO EN SISTEMAS INDUSTRIALES*

El mantenimiento predictivo (PdM, predictive maintenance) se refiere a la planificación de intervenciones de mantenimiento basadas en el estado real de los equipos, pronosticando fallos antes de que ocurran. A diferencia del mantenimiento reactivo (tras una avería) o preventivo (según calendario fijo), el PdM busca optimizar recursos y minimizar tiempos de parada innecesarios. Según Jardine et al., el PdM tiene como finalidad “reducir el mantenimiento no necesario, optimizar el uso de recursos de mantenimiento y minimizar el tiempo de inactividad”. Esto se consigue analizando datos históricos y en tiempo real de sensores industriales para identificar patrones indicativos de futuras fallas. [15]

Hay varios estudios que reportan beneficios cuantificables: por ejemplo, la aplicación de inteligencia artificial al PdM puede resultar en una reducción de hasta un 30% en los tiempos de inactividad no planificados, acelerar en un 83% la resolución de incidencias y disminuir en 75% el tiempo dedicado a mantenimiento. Como resultado, estas mejoras se traducen en mayor disponibilidad de los activos, reducción de costes operativos y aumento de la seguridad y satisfacción tanto de operadores como de clientes [16].

En la era de la Industria 4.0, el PdM usa como apoyo los sensores IoT y el análisis de datos avanzados para monitorizar condiciones como vibraciones, temperaturas, presiones, corrientes, etc., de forma continua. Al exceder, estas mediciones, umbrales o al mostrar anomalías, el sistema emite alertas y permite planificar una intervención antes de que ocurra una catástrofe. Un ejemplo de aplicación crítica es en bombas de agua industriales. Estas bombas son componentes esenciales en plantas de producción, sistemas de bombeo de agua, circuitos de refrigeración y otros procesos. En una bomba, si se da un fallo inesperado, puede detener operaciones enteras y, por ello, detectar signos de degradación con antelación es clave para mitigar sus efectos en la operación, mantenimiento y costos.

Estudios en plantas de energía han demostrado que la detección temprana de anomalías en bombas de agua de circulación ayuda a prevenir daños mayores y optimizar las actividades de mantenimiento programadas [17].

Tradicionalmente, el mantenimiento condicionado (CBM) está basado en análisis estadísticos sencillos o en reglas basadas en la experiencia del personal, pero estos métodos pueden fallar ante datos complejos. En los últimos años, ha habido avances en aprendizaje automático (Machine Learning o ML) que han impulsado un cambio clave, proporcionando modelos más precisos y capaces de manejar la complejidad de sistemas interconectados [15][10]. A continuación, se muestran las principales metodologías de aprendizaje automático aplicadas al PdM en la literatura, con énfasis en aplicaciones a bombas de agua, y comparando sus enfoques y sus resultados más relevantes.

3.2 METODOLOGÍAS DE MACHINE LEARNING APLICADAS AL PdM

Para el mantenimiento predictivo, se han empleado números enfoques de ML. En términos generales, se pueden agrupar en: (1) métodos de aprendizaje automático “tradicional” (algoritmos de clasificación/regresión supervisada como árboles de decisión, bosques aleatorios y SVM), (2) técnicas de aprendizaje profundo (redes neuronales convolucionales, recurrentes y autoencoders) y (3) modelos híbridos que combinan múltiples técnicas o

incorporan conocimiento físico del sistema. A continuación, se analiza cada categoría y estudios representativos.

3.2.1 ALGORITMOS SUPERVISADOS TRADICIONALES (ÁRBOLES DE DECISIÓN, RANDOM FOREST, Y SVM)

Los primeros enfoques de PdM con ML utilizaron algoritmos supervisados clásicos, que se aprecian por su interpretabilidad moderada y menor requerimiento de datos en comparación con las redes profundas. Entre ellos destacan los árboles de decisión y sus agregados, como Random Forest y Gradient Boosting, así como las Máquinas de Vectores de Soporte (SVM) para clasificación o regresión. Estas técnicas han conseguido demostrar un buen desempeño en la detección de fallos incipientes y estimación de vida útil cuando se cuenta con las características adecuadas extraídas de los sensores [10]. Por ejemplo, Silva & Capretz en su estudio emplearon un enfoque de clasificadores múltiples para PdM, combinando árboles de decisión, SVM y otros algoritmos, logrando una mejor precisión en la detección de fallos de sistemas de fabricación comparado a usar un único modelo [9].

En aplicaciones a bombas de agua, algoritmos como Random Forest han mostrado resultados sobresalientes. Un ejemplo de un estudio relevante en este sector es la tesis de Benavente Álvarez, que aplicó Random Forest para predecir el estado futuro de bombas multietapa a partir de series temporales de sensores. Este modelo superó claramente a una regresión lineal multivariante usada como referencia: con datos de entrenamiento adicionales, el Random Forest obtuvo un error $RMSE = 0,037$ ($MAE = 0,006$) frente a $RMSE = 0,070$ ($MAE = 0,044$) de la regresión, casi un 50% menos error de predicción. Este resultado confirma la capacidad del bosque aleatorio para capturar relaciones no lineales y dependencias temporales mejor que un modelo lineal sencillo en datos de bombas [20].

Otro estudio destacable es el de Chhabria et al., en el cual se desarrolló un sistema IoT de mantenimiento predictivo para bombas de agua industriales utilizando un clasificador Random Forest como herramienta principal. Con el uso de datos reales de operación y eventos de fallo en bombas, se logró una exactitud del 97%, con recall de aproximadamente un 96,5% y precisión de 98% en la detección de fallos incipientes [11]. Indicando que casi

todos los fallos fueron anticipados correctamente con pocos falsos positivos. Adicionalmente, el Random Forest demostró ser robusto a ruido y eficiente en computación, muy relevante para el análisis en tiempo real. Por otro lado, se identificaron desafíos prácticos, como la preparación de datos (limpieza y sincronización de múltiples sensores) y la consistencia de las lecturas en el tiempo [11].

Además, se han aplicado las SVM con éxito en el ámbito del PdM, especialmente para clasificación de estados de maquinaria. Cabe destacar, al autor Bartolomé, que exploró algoritmos de clasificación binaria (SVM y regresión logística) en un conjunto de datos industriales [19]. En esta investigación, se encontró que ambos podían clasificar correctamente el estado de los equipos, y que la elección óptima dependía del objetivo concreto (maximizar exactitud global vs. minimizar falsos negativos). Por lo general, las SVM consiguen una alta precisión cuando las fronteras entre clases son definidas, pero requieren un esfuerzo en la selección del kernel y pueden escalar mal con datos muy grandes.

Método	Exactitud	Precisión	Sensibilidad
Random Forest	98,95%	98,33%	99,57%
SVM	99,37%	98,95%	99,78%
Gradient Boosting	99,05%	98,74%	99,36%
XGBoost	99,26%	98,95%	99,57%
KNN	99,05%	98,53%	99,57%
Naive Bayes	98,21%	96,91%	99,57%
Árbol de decisión	98,01%	99,13%	96,83%

Tabla 1. Comparación de métodos de ML. Fuente: Benavente Álvarez [20]

Cuando hablamos de bombas de agua, algoritmos basados en árboles suelen ser preferibles por su capacidad de manejar variables de distinto tipo y de reflejar relaciones no lineales entre variables de sensor (caudal, presión, vibración, temperatura, etc.). En resumen, los métodos supervisados tradicionales han demostrado su efectividad para PdM, alcanzando en muchos casos precisiones superiores al 95-99%. Sus ventajas incluyen la robustez con datos tabulares y la disponibilidad de técnicas maduras de feature engineering. Como limitaciones,

suelen requerir la extracción manual de características apropiadas (estadísticas de vibración en el dominio del tiempo o frecuencia), y no es fácil de capturar las dependencias complejas en secuencias temporales largas. Estas limitaciones han impulsado la adopción de enfoques de deep learning que automatizan la extracción de patrones temporales.

3.2.2 REDES NEURONALES Y APRENDIZAJE PROFUNDO (CNN, LSTM, AUTOENCODERS)

En esta sección, se describe como el aprendizaje profundo ha ganado prominencia en el mantenimiento predictivo en la última década, gracias a su capacidad para modelar relaciones complejas y procesar grandes volúmenes de datos de sensores. Dos arquitecturas que destacar son las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (especialmente la variante LSTM, Long Short-Term Memory), además de modelos híbridos o variantes (como autoencoders o transformadores). Estas técnicas consiguen evitar la necesidad de diseñar manualmente las características, ya que pueden aprender directamente de los datos brutos secuenciales o multivariantes.

Las CNN se han aplicado en PdM mayormente para el análisis de formas de onda de sensores o imágenes espectrales. Una estrategia común es utilizar CNN 1D sobre señales temporales (vibración, sonido) para extraer automáticamente características relevantes de la señal. Por otro lado, existen las CNN 2D que se aplican cuando las series temporales se convierten en imágenes (por ejemplo, espectrogramas tiempo-frecuencia). En cualquier caso, las CNN pueden detectar patrones locales (frecuencias de fallo, transitorios) que están asociados a defectos incipientes.

En el estudio de Nasser & Al-Khazraji, se propuso un esquema que resaltaba las CNN combinada con LSTM para detectar fallos en maquinaria industrial. Esta arquitectura híbrida (CNN-LSTM) emplea convoluciones para capturar características locales de la serie temporal, alimentando luego esas características a capas LSTM que modelan las dependencias de largo plazo. Al probarlo en un conjunto de datos público de producción industrial, resultó en una mejora significativa en la precisión frente a modelos tradicionales: el modelo híbrido obtuvo un F1-score de 97,48%, superando en un 4,4% al mismo modelo

usando solo LSTM (93% F1) [12]. En términos de precisión y recall, el CNN-LSTM logró aproximadamente un 97,6% y 97,4% respectivamente, destacando sobre otros enfoques previos en la literatura [12]. Con este resultado se confirma el valor de combinar CNN (robusta extrayendo patrones locales de sensores) con LSTM (especializada en secuencias) para mejorar la detección de fallos.

De la misma manera, Zhao et al. emplearon una CNN profunda capaz de predecir fallos en sistemas de bombeo, obteniendo unas mejoras de al menos 1,5% en exactitud frente a otros algoritmos probados [18]. Los autores atribuyen este avance a la capacidad de la CNN de detectar indicadores tempranos de fallo que preceden a la degradación severa. Una desventaja es que las CNN requieren conjuntos de datos grandes para entrenar sus numerosos parámetros, sin datos suficientes existe riesgo de sobreajuste o de obtener resultados inferiores a métodos más simples. No obstante, a medida que en entornos industriales se acumulan más datos de sensores (gracias a IoT), las CNN pueden entrenarse más profundamente para alcanzar niveles aún mayores de rendimiento [18].

Por su parte, las redes LSTM se han consolidado como una herramienta fundamental para el PdM orientado a predecir series temporales, especialmente para estimar la vida útil remanente (RUL) de componentes. En concreto, las LSTM son capaces de retener información a largo plazo de la secuencia de datos, lo cual es crucial cuando los indicios de fallo se desarrollan gradualmente. Un trabajo relevante es el de De Vita & Bruneo, donde investigan la predicción de la RUL de motores turbofan (dataset NASA C-MAPSS) usando LSTM. En su estudio, exploraron distintos hiperparámetros de la red (número de capas, neuronas, función de activación, etc.) para tener un mayor entendimiento de su influencia en el rendimiento. Posteriormente, diseñaron este modelo LSTM optimizado que superó a soluciones previas de la literatura en ese benchmark estándar [10].

Para complementar al estudio anterior, Kim & Choi abordaron la optimización de redes LSTM para PdM mediante algoritmos genéticos, logrando identificar configuraciones de hiperparámetros óptimas que mejoraban la eficiencia del modelo sin sacrificar precisión [8]. En su estudio, disminuyeron la dimensionalidad de las entradas usando análisis de

correlación antes de entrenar la LSTM, lo que mejoró la estabilidad de las predicciones. En general, las LSTM han demostrado eficacia al capturar la evolución temporal de parámetros como vibración o temperatura para anticipar los fallos. Su ventaja es modelar dinámicas temporales complejas mejor que métodos estáticos, aunque, como desventaja, pueden requerir mucho tiempo de entrenamiento y ser difíciles de interpretar. Además, estos modelos necesitan grandes cantidades de datos etiquetados con fallos para generalizar bien, algo no siempre disponible.

Más recientemente han surgido enfoques con Redes Generativas Adversarias (GAN) para sintetizar datos de fallo escasos, o modelos tipo Transformer para analizar series muy largas, aunque su uso en PdM de bombas es aún incipiente en la literatura revisada.

En resumen, el aprendizaje profundo aporta mejoras notables en PdM al extraer automáticamente características complejas y considerar relaciones no lineales y temporales. Las CNN y LSTM (y combinaciones de ambas) han alcanzado métricas de precisión muy elevadas (a menudo >95% en entornos controlados) y reducciones de error significativas en estimaciones de RUL. Sin embargo, todavía existen desafíos de datos (necesidad de grandes volúmenes representativos, incluyendo suficientes ejemplos de fallo) y de computación (entrenamiento más lento, requerimiento de GPU en muchos casos).

3.2.3 ENFOQUES HÍBRIDOS Y MODELOS AVANZADOS (GEMELOS DIGITALES, COMBINACIONES)

Esta sección de enfoques híbridos engloba aquellas estrategias que combinan algoritmos de ML con modelos basados en la física o con múltiples técnicas complementarias. El objetivo es aprovechar conocimiento experto o simulado del sistema para suplir la escasez de datos de fallos, mejorar la interpretabilidad de las predicciones o incrementar la robustez del diagnóstico. Un ejemplo destacado es el concepto de gemelo digital aplicado al PdM. Un gemelo digital es una réplica virtual del sistema físico (una bomba) que simula su comportamiento en tiempo real.

En un estudio reciente, Sanz-Bobi et al. emplearon esta idea para la detección de anomalías en una bomba de agua de refrigeración de una central térmica. Construyeron dos gemelos digitales de la bomba utilizando dos enfoques de deep learning: redes neuronales profundas entrenadas con datos históricos, y aprendizaje por refuerzo (RL) para modelar la dinámica del sistema. Cada gemelo virtual era capaz de predecir la evolución esperada de variables clave de la bomba en condiciones normales, como temperaturas de cojinetes, vibraciones en puntos críticos, o caudales, usando únicamente las entradas de operación habituales [17]. De esta manera, cualquier desviación significativa entre los valores medidos por los sensores y las predicciones del gemelo digital señalaba una potencial anomalía o modo de fallo incipiente. Esta aproximación dio lugar a la detección de patrones sutiles de degradación con suficiente antelación para tomar medidas, integrándose como un componente de un programa amplio de gestión de activos (Prognostics and Health Management, PHM) [17].

El enfoque de gemelo digital ofrece ventajas claras como aprovechar los conocimientos físicos (a través de simulación) junto con datos para cubrir casos de fallos poco frecuentes, y proporciona un marco para diagnosticar si algo va mal y qué podría estar fallando. Como desventaja, su implementación es compleja, requiriendo modelar con alta fidelidad el sistema y asegurando que el gemelo permanezca actualizado frente a cambios en el equipo o condiciones de operación.

Otro enfoque híbrido que destacar sería la combinación de modelos basados en conocimiento físico con modelos de datos. Por ejemplo, Wang et al. propusieron una estrategia mixta de mantenimiento predictivo y mantenimiento proactivo en equipos de potencia ferroviarios [7]. Emplearon un predictor de mantenimiento basado en LSTM para pronosticar el tiempo hasta el fallo a partir de datos históricos (enfoque puramente data-driven), sumándole un generador de muestras sintéticas basado en modelos físicos de degradación (enfoque model-based). Esta sinergia consiguió resolver un problema común que es la escasez de datos de fallo en sistemas nuevos. Al generar datos de fallo simulados mediante el modelo físico (proactivo) y combinarlos con los algoritmos de deep learning (predictivo), lograron mejorar la precisión de predicción de fallos en un sistema de interruptores de alta tensión.

Este tipo de enfoques híbridos data-físico es muy prometedor en PdM, ya que aprovecha al máximo la información disponible de ambas fuentes. Finalmente, dentro de los enfoques híbridos también podemos incluir las técnicas de algunos estudios que emplean primero algoritmos no supervisados (como clustering o autoencoders) para detectar anomalías y luego modelos supervisados para diagnosticar la causa. Con esto, se construye un pipeline de mantenimiento predictivo más completo y aporta ventajas en precisión o generalización, a costa de mayor complejidad en su desarrollo e interpretación.

3.2.4 COMPARACIÓN DE ENFOQUES Y RESULTADOS

La Tabla 2 resume varios estudios clave de mantenimiento predictivo aplicando técnicas de ML a bombas de agua u otros sistemas industriales relacionados. Esta comparación permite visualizar las tendencias en la literatura y las brechas que el presente trabajo pretende abordar.

Estudio (año)	Sistema Datos	Técnicas empleadas	ML	Métricas Obtenidas
Benavente Álvarez (2024) [20]	Bomba multietapa (mina); 6 meses datos históricos (presión, caudal, vibración).	Random Forest vs. Regresión lineal múltiple.		RF con RMSE=0,037, MAE=0,006 (frente a RMSE=0,070, MAE=0,044 de regresión). Precisión de RF ~99%.
Chhabria et al. (2022) [11]	Bombas de agua industriales; datos IoT en tiempo real (T°, vibración, sonido, voltaje).	Random Forest (clasificación binaria de estado).		Exactitud 97%, Recall 96,5%, Precisión 98%. Detección temprana de fallos incipientes.

Nasser & Al-Khazraji (2022) [12]	Sistema de producción con múltiples componentes; dataset público turbinas (UCI).	Red neuronal híbrida CNN-LSTM; comparación con LSTM pura.	F1-score 97,5% (Prec. 97,6%, Rec. 97,4%). Mejora +4,4 puntos vs. LSTM solo (F1 ~93,3%).
Sanz-Bobi et al. (2024) [17]	Bomba de agua de refrigeración en central térmica; datos operativos SCADA (varios años).	Gemelo digital con modelos de Deep Learning (red neuronal profunda y modelo de aprendizaje por refuerzo).	DLNN: RMSE medio $\approx 0,17$ °C; STD hasta 1,36 °C. TD3: RMSE medio $\approx 0,05$ °C; STD hasta 0,99 °C. Ambos detectaron anomalía simulada de +2,5 °C.

Tabla 2. Comparativa de estudios representativos de PdM con machine learning en bombas de agua y sistemas afines. Fuente: Elaboración propia.

Diversos estudios han demostrado que los algoritmos de aprendizaje automático son altamente eficaces en mantenimiento predictivo, logrando precisiones superiores al 95–99 % en clasificación de fallos, siempre que los datos sean adecuados. Tanto modelos tradicionales como Random Forest y SVM, como redes neuronales profundas, ofrecen rendimientos similares en problemas bien definidos, por lo que la elección suele depender de aspectos prácticos como velocidad, interpretabilidad o integración con infraestructuras IoT.

En tareas de pronóstico continuo, como la estimación de vida útil remanente (RUL), los modelos basados en series temporales, como las redes LSTM, son preferibles, ya que capturan mejor las dependencias de largo plazo que métodos como la regresión o Random Forest sin tratamiento temporal. El trabajo de Benavente lo confirma al mostrar que incorporar ventanas temporales en el modelado mejora significativamente la precisión en la predicción del deterioro de bombas [20]. En resumen, para problemas dependientes del

historial, las arquitecturas de deep learning secuenciales suelen rendir mejor, aunque a costa de mayor complejidad.

Los estudios revisados utilizan principalmente métricas como exactitud, precisión, recall, F1 y RMSE/MAE, según el tipo de tarea (clasificación o regresión). En mantenimiento predictivo, es clave considerar el desbalance de clases, ya que los fallos son eventos poco frecuentes. Por eso, métricas como el recall para la clase de fallo y la precisión son más representativas que la exactitud global. Algunos trabajos, como el de Chhabria et al. (2022), destacan por mantener altos valores en ambas (~96–98 %), lo que indica modelos efectivos y equilibrados [11]. Esto es crucial en PdM ya que un modelo ideal debe dar alerta de todos (o casi todos) los fallos verdaderos con antelación suficiente (alto recall), evitando a la vez disparar alarmas innecesarias que resulten en inspecciones o paradas improductivas (alto precision).

En resumen, las distintas técnicas de ML aplicadas al mantenimiento predictivo presentan ventajas y limitaciones complementarias como se han mencionado anteriormente. Los modelos basados en árboles, como Random Forest o XGBoost, destacan por su robustez y manejabilidad con datos tabulares, aunque requieren ingeniería manual para tratar secuencias temporales. Las SVM ofrecen alta precisión en conjuntos bien definidos, pero escalan mal con grandes volúmenes de datos. Por otra parte, las redes neuronales profundas (CNN, LSTM) son especialmente eficaces en el tratamiento de datos complejos y multicanal, aunque implican mayor complejidad, necesidad de datos y menor interpretabilidad. Finalmente, los enfoques híbridos, amplían el contexto y la capacidad diagnóstica del sistema, aunque con un coste de implementación elevado que limita su adopción a entornos industriales más avanzados. La elección del enfoque óptimo dependerá, por tanto, del tipo de sistema, la disponibilidad de datos, los recursos técnicos y los objetivos específicos del mantenimiento.

3.3 CONTRIBUCIÓN Y BRECHAS IDENTIFICADAS

La revisión de la literatura demuestra que existen múltiples técnicas de ML con alto potencial para el mantenimiento predictivo de bombas, especialmente cuando se utilizan datos procedentes de sensores industriales. Sin embargo, también pone de manifiesto una serie de limitaciones comunes: muchos estudios se centran en contextos muy controlados o en un único algoritmo, dificultando la comparación sistemática entre enfoques, mientras que otros no trasladan los resultados a un análisis más operativo sobre qué implica realmente una predicción de fallo.

Este estudio contribuye al estado del arte mediante el desarrollo de una metodología basada en el entrenamiento de modelos individuales que representan el comportamiento normal de diferentes variables clave asociadas a modos de fallo (temperatura de cojinetes, intensidades de motor, caudal de descarga) en bombas de agua de circulación. Estos modelos, construidos con redes convolucionales, aprenden la relación esperada entre entradas y salidas bajo condiciones nominales, utilizando un año de datos históricos como referencia (sin intervenciones ni anomalías). A partir de ahí, se proyectan los modelos a años posteriores para analizar las desviaciones y detectar signos tempranos de degradación funcional.

Una aportación importante de este trabajo es el cálculo de curvas de estrés acumulado, que se generan a partir de errores que superan un umbral definido (basado en la desviación estándar del error de entrenamiento). Estas curvas permiten visualizar y cuantificar cómo evoluciona el estado de salud de cada componente monitorizado a lo largo del tiempo. Se ha desarrollado también un modelo basado en redes LSTM, entrenado sobre las curvas de estrés, para predecir su evolución futura y estimar con antelación si se alcanzará un umbral crítico que justifique una intervención de mantenimiento.

Otra característica relevante es que el estudio se aplica a dos bombas distintas del mismo sistema, entrenando modelos separados para cada una y permitiendo compararlas en cuanto a evolución del deterioro, respuesta a las acciones de mantenimiento, y coste potencial asociado. Esta comparación no solo valida la capacidad general de los modelos para detectar

anomalías incipientes, sino que también permite optimizar recursos priorizando intervenciones donde sean más necesarias.

Además, se abordan aspectos prácticos clave poco tratados en otros estudios, como:

- La robustez frente a datos ruidosos o desbalanceados.
- El valor real de una predicción desde la perspectiva operativa (por ejemplo, anticipar con precisión un fallo dos días antes puede ser más útil que detectarlo con altísima confianza solo dos horas antes).
- La evaluación post-mantenimiento, verificando si el error disminuye tras la intervención y, por tanto, si fue efectiva.

En conclusión, este trabajo aporta una metodología aplicable a entornos industriales reales, centrada en entender y modelar el comportamiento normal de bombas de agua de circulación, detectar anomalías incipientes, y anticipar su evolución. Además de validar herramientas de ML, se avanza hacia una visión más operativa del mantenimiento predictivo, con resultados que pueden informar tanto la planificación técnica como la toma de decisiones económicas sobre mantenimiento.

Capítulo 4. DEFINICIÓN DEL TRABAJO

4.1 JUSTIFICACIÓN

El mantenimiento predictivo es considerado una herramienta estratégica de gran necesidad en entornos industriales donde la fiabilidad y la continuidad operativa son críticas. Más concretamente, es una herramienta clave en los sistemas de refrigeración industrial mediante bombas de agua de circulación donde cualquier fallo inesperado puede provocar consecuencias graves, tanto en términos de paradas de producción como de riesgos operativos y sobrecostes energéticos. Este tipo de equipos opera de forma continua y, por tanto, está sometido a procesos de desgaste gradual difíciles de detectar con métodos tradicionales.

A pesar de algunos avances en la digitalización industrial, muchas estrategias de mantenimiento predictivo se basan en umbrales estáticos o reglas fijas, que ofrecen una sensibilidad limitada y no siempre permiten anticiparse a fallos incipientes. La capacidad de intervención a tiempo se ve afectada por esta falta de anticipación y obliga a realizar mantenimientos correctivos urgentes con el consiguiente impacto económico y logístico.

Este estudio surge precisamente de esas limitaciones, de la necesidad de diseñar un sistema más robusto y dinámico que permita identificar patrones de deterioro en etapas anteriores. La motivación principal es ofrecer al equipo de mantenimiento una herramienta que no solo detecte anomalías con mayor precisión, sino que también proporcione información útil para optimizar la planificación de intervenciones, reducir el número de paradas no programadas y maximizar la vida útil de los componentes.

De la misma manera, la comparación entre las arquitecturas neuronales empleadas como CNN y LSTM responde a la necesidad de establecer criterios técnicos sólidos que orienten la elección de modelos en función del tipo de variable y del comportamiento dinámico del sistema. Este trabajo no trata solo de aplicar algoritmos avanzados, sino de construir una

metodología evaluable, replicable y alineada con los objetivos reales de la industria: reducir costes, mejorar la eficiencia y aumentar la fiabilidad operativa.

4.2 OBJETIVOS

El objetivo principal de este trabajo, como se ha mencionado anteriormente, es mejorar la eficiencia operativa y la fiabilidad del sistema de bombeo de agua de circulación mediante la aplicación de técnicas de mantenimiento predictivo basadas en modelos de aprendizaje automático. Se busca la anticipación de los fallos incipientes en los componentes críticos de las bombas, con el fin de reducir el número de paradas imprevistas, minimizar los costes asociados a mantenimientos correctivos y aumentar la disponibilidad del sistema.

Para desarrollar este enfoque, se establece como objetivo más específico la comparación entre dos tipos de modelos de predicción, concretamente CNN y LSTM, con el propósito de evaluar cuál ofrece un mayor rendimiento en la detección temprana de fallos. Lo que permitirá esta comparación es orientar las futuras decisiones sobre qué arquitectura resulta más adecuada en entornos industriales con características similares.

Por otro lado, un objetivo relevante es la mejora de la planificación del mantenimiento, gracias a la identificación temprana de desviaciones en el comportamiento normal de las variables operativas. Esta capacidad de anticipación ayuda en la toma de decisiones técnicas y permite programar las intervenciones en momentos óptimos, evitando fallos catastróficos y sustituciones prematuras innecesarias que resulten en costes mayores.

Además, se busca proporcionar a los responsables de mantenimiento herramientas gráficas y de análisis que reflejen de manera concisa el nivel de estrés de cada componente, en combinación con fechas reales de los mantenimientos que se han realizado. Esto permitirá evaluar la efectividad de las actuaciones realizadas y ajustar estrategias futuras en función de su impacto real sobre el estado de los equipos.

Finalmente, se pretende llegar a la validación de la metodología desarrollada en más de una unidad del sistema, lo que permitirá demostrar su aplicabilidad y escalabilidad, y garantizar

que los resultados obtenidos no dependen exclusivamente de las características de una única bomba.

4.3 METODOLOGÍA

Durante este trabajo, la metodología empleada ha sido estructurada como un proceso completo de mantenimiento predictivo basado en el modelado del comportamiento normal de las bombas de agua de circulación, seguido de una evaluación comparativa entre dos arquitecturas de redes neuronales: CNN y LSTM. El enfoque parte de la hipótesis de que cada variable operativa dispone de un patrón esperable bajo condiciones normales, y que cualquier desviación que se salga de ese patrón puede ser interpretada como un indicio de deterioro de la bomba.

La primera fase del estudio trata de la limpieza y preprocesamiento de los datos históricos, proporcionados por la empresa, recogidos por los sensores de planta. A estos datos se les aplican filtros por percentiles para eliminar valores atípicos, se descartan registros incompletos, se renombran y estandarizan las variables para asegurar coherencia semántica y técnica, y se normalizan los datos para su posterior uso en modelos neuronales. Esta preparación garantiza que los modelos se entrenen sobre datos consistentes y comparables.

Además, con el fin de realizar un análisis exploratorio completo antes del entrenamiento de los modelos, se han generado diversas visualizaciones que permiten comprender mejor la distribución y comportamiento de las variables. Entre ellas se incluyen diagramas de correlación entre variables, histogramas para analizar la distribución de frecuencias, y diagramas de caja (boxplots) para identificar la presencia de valores atípicos.

En la siguiente fase, se lleva a cabo el entrenamiento de los modelos de redes neuronales convolucionales (CNN) para cada variable crítica. Estas redes se ajustan bien al análisis de series temporales multivariadas, permitiendo capturar relaciones locales entre variables sin necesidad de transformaciones complejas. Para cada modelo se selecciona un año de referencia (2020 en general, 2021 para variables de temperatura de cojinetes) con un historial

sin incidencias conocidas. Una vez entrenados, se evalúa el error de predicción de cada modelo y se calcula su desviación estándar. Esta información se utiliza para definir bandas de confianza individuales, típicamente de ± 2 desviaciones estándar.

Los modelos CNN se aplican a datos de años posteriores al de entrenamiento para calcular el error entre valor real y predicho. Cuando dicho error excede las bandas de confianza, se considera que existe una desviación anómala. Estos eventos anómalos se acumulan generando las denominadas curvas de estrés, que son gráficas que muestran, de forma progresiva, cuántas veces una variable ha salido de su comportamiento esperado. Una pendiente pronunciada en estas curvas indica un aumento sostenido del deterioro.

A continuación, se representan gráficamente las curvas obtenidas junto con las fechas reales de mantenimiento correctivo y preventivo, registradas en planta, que puedan afectar a cada modelo según la variable estudiada. Esta superposición permite observar si una intervención ha logrado estabilizar la evolución del deterioro o si el sistema ha seguido empeorando. A través de esta observación se puede valorar la efectividad real de las acciones de mantenimiento.

Más adelante, el proceso empleado se replica utilizando redes neuronales LSTM. Estos modelos están específicamente diseñados para capturar dependencias temporales de largo plazo, por lo que se entrenan sobre secuencias de 144 muestras consecutivas (equivalente a un día de operación, 6 muestras por hora por 24 horas). Repitiendo el proceso de las CNN, se entrenan modelos por variable, se calcula el error de predicción, se aplican las bandas de confianza y se generan nuevas curvas de estrés acumulado. Estas curvas también se grafican junto con las fechas de mantenimiento, replicando de forma exacta el proceso anterior.

La fase final de la metodología consiste en la comparación directa entre las curvas de estrés acumulado generadas por ambos enfoques, CNN y LSTM, bajo condiciones idénticas. Se generan gráficas comparativas donde ambas curvas se representan sobre el mismo eje temporal, junto con las fechas de intervención. Esta comparación permite analizar qué arquitectura es más sensible, cuál detecta antes los signos de deterioro, y en qué casos se comportan de forma similar o divergente.

Toda esta metodología se ha implementado y validado sobre dos bombas diferentes del mismo sistema de agua de circulación. Primero se ejecuta el flujo completo sobre la Bomba 1 y, una vez completado, se repite con la Bomba 2. Esto permite contrastar el rendimiento de los modelos y, también, la evolución operativa relativa de ambas bombas y la escalabilidad del sistema desarrollado.

La figura siguiente representa de forma esquemática el conjunto de fases descritas:



Figura 4. Fases de la metodología. Fuente: Elaboración propia.

4.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

El desarrollo del trabajo ha durado un periodo aproximado de siete meses, siguiendo una planificación escalonada y coherente con la estructura metodológica del proyecto. La Figura 5 muestra de forma visual la distribución temporal de las distintas tareas, desde las fases

iniciales de análisis documental hasta las actividades finales de validación y conclusiones:




Figura 5. Gantt Chart. Fuente: Elaboración propia.

Realizando un análisis de las tareas realizadas, las más exigentes en términos de dedicación y complejidad han sido, primero, la limpieza y el preprocesamiento de los datos. Durante esta etapa era necesario un trabajo meticuloso para establecer correctamente los límites y el comportamiento esperado de cada variable para su posterior modelado. A esto se le añade el análisis individualizado de cada variable, ya que cada una presenta unas características operativas distintas, lo que obligó a estudiar sus necesidades específicas y realizar un ajuste preciso de los umbrales de funcionamiento normal. Además, los datos proporcionados estaban etiquetados mediante sistemas de codificación técnica compleja, lo que hizo que la identificación y el tratamiento de cada señal fuesen tareas especialmente delicadas.

Una vez completada esta fase, el siguiente gran reto fue el entrenamiento de los modelos y el ajuste de sus hiperparámetros. Este proceso requirió una supervisión minuciosa para garantizar una convergencia estable y un rendimiento fiable. Posteriormente, se llevó a cabo un análisis comparativo entre las arquitecturas CNN y LSTM aplicadas a ambas bombas, combinando tanto métricas cuantitativas como evaluaciones visuales. Este enfoque permitió identificar diferencias relevantes en cuanto a la sensibilidad de los modelos, su capacidad para anticipar anomalías y su alineación con los eventos reales de mantenimiento. Estos resultados resultaron esenciales para valorar la aplicabilidad y robustez de cada arquitectura en contextos industriales reales.

Más adelante, el análisis del mantenimiento representó otra fase clave en el desarrollo del trabajo. En este punto, se cruzaron las curvas de desviación acumulada con los registros

reales de mantenimiento preventivo y correctivo, lo que permitió contextualizar los eventos detectados por los modelos y plantear ajustes metodológicos relevantes. Por ejemplo, en ciertos casos fue necesario modificar el año de referencia inicialmente previsto, al observar que en 2021 la bomba mostraba un comportamiento notablemente más estable que en 2020 debido a una intervención de mantenimiento intermedia. Este tipo de observaciones ha sido esencial para asegurar que el entrenamiento se realizara sobre datos verdaderamente representativos del estado normal de funcionamiento.

.

Capítulo 5. SISTEMA/MODELO

DESARROLLADO

5.1 ANÁLISIS DEL SISTEMA

El sistema desarrollado constituye una herramienta modular de mantenimiento predictivo, orientada a la detección temprana de deterioros en las bombas de agua de circulación mediante el análisis automático de variables operativas. El diseño sirve para integrarse con sistemas industriales que ya disponen de sensores de proceso, procesando datos históricos de forma autónoma y generando salidas visuales que permiten apoyar las decisiones de intervención.

Por otro lado, el sistema se basa en el modelado del comportamiento normal de cada variable significativa a través de técnicas de aprendizaje automático. Existen otros enfoques basados en reglas fijas o umbrales estáticos, pero el sistema planteado en el trabajo es capaz de aprender directamente el funcionamiento estable de cada bomba, permitiéndole adaptarse a las particularidades de cada señal. A partir de esto, el sistema identifica de forma automatizada desviaciones que pueden representar un riesgo operativo, las acumula en forma de curvas de estrés y las contextualiza con el historial de mantenimiento registrado.

La arquitectura ha sido implementada sobre dos bombas técnicamente equivalentes, que forman parte del mismo sistema hidráulico, pero con trayectorias independientes de uso y mantenimiento. Esta metodología ha permitido verificar la replicabilidad del sistema sin requerir rediseños estructurales y ha demostrado su potencial para ser reutilizado en otros activos industriales con configuraciones similares.

El sistema se presenta como un conjunto autónomo, organizado en módulos independientes pero conectados: desde la carga y tratamiento de los datos, hasta el entrenamiento de los modelos predictivos, la identificación de fallos y la generación de visualizaciones

interpretables. Esta estructura facilita el mantenimiento, la evolución en un futuro y su adaptación a nuevas plantas o conjuntos de variables.

5.2 GESTIÓN DE SEÑALES Y VARIABLES

El sistema desarrollado se basa en un conjunto específico de variables operativas seleccionadas por su capacidad para reflejar el estado funcional de las bombas de agua de circulación desde diferentes perspectivas. Estas señales están disponibles de manera continua en los registros de planta y, además, tienen una relación directa con distintos modos de fallo relevantes en este tipo de equipos. A continuación, se realizará una descripción del rol funcional de cada una de las variables dentro del sistema y el valor que aportan en el esquema de mantenimiento predictivo.

- **Temp_Fase_R_Motor, Temp_Fase_S_Motor, Temp_Fase_T_Motor:**
Estas tres variables registran la temperatura de cada fase del bobinado del motor eléctrico. Son fundamentales a la hora de detectar desequilibrios térmicos que pueden deberse a asimetrías de carga, fallos en el aislamiento o defectos específicos en una de las fases. Un aumento generalizado en estas temperaturas también puede indicar sobreesfuerzo mecánico, deficiencias en el sistema de ventilación o fricción interna. Su análisis permite anticipar fallos eléctricos y problemas indirectos derivados del acoplamiento bomba-motor.
- **Int_Fase_R_Motor, Int_Fase_S_Motor, Int_Fase_T_Motor:**
Las intensidades por fase del motor trifásico reflejan la corriente que circula en cada instante. Estas señales son clave para detectar desequilibrios entre fases, sobrecargas sostenidas, arranques forzados o transitorios anómalos. Variaciones prolongadas o desproporcionadas entre fases, así como un aumento notable de las intensidades, pueden ser síntoma de deterioros en el devanado, fallos en el sistema de alimentación o incluso daños mecánicos reflejados en el comportamiento eléctrico.

- **Temperatura del cojinete radial del lado del acoplamiento, Temperatura del cojinete radial opuesto al acoplamiento:**

Estas variables térmicas indican la condición mecánica de los cojinetes que soportan el eje de la bomba. El aumento sostenido de temperatura en estas zonas suele ser consecuencia de fricción excesiva, deficiente lubricación o desgaste por carga desalineada. Como los cojinetes son componentes críticos cuya falla puede provocar la parada completa del equipo, su vigilancia térmica representa un elemento central en cualquier estrategia de mantenimiento predictivo.

- **Caudal de descarga de la bomba:**

El caudal de descarga es una medida directa del rendimiento hidráulico de la bomba. Su evolución a lo largo del tiempo permite identificar pérdidas progresivas de eficiencia, que pueden estar asociadas a cavitación, obstrucciones parciales, erosión interna del rodete o deterioro estructural. Su análisis combinado con la presión de impulsión y el nivel de cántara permite contextualizar correctamente las exigencias hidráulicas del sistema y discriminar entre causas externas e internas de pérdida de rendimiento.

Para cada variable objetivo, se ha definido un conjunto de variables de entrada seleccionadas en base a principios técnicos. Por ejemplo, para modelar la temperatura de cojinete se utiliza la intensidad media del motor y la presión de descarga, ya que estas tienen influencia directa en la carga térmica soportada por el eje. Esta asociación se formaliza mediante estructuras tipo diccionario (`model_inputs`, `output_columns`) que permiten automatizar el entrenamiento y evaluación de modelos por variable.

La separación explícita entre variables de entrada y de salida facilita la replicación del sistema, permitiendo su extensión a otras bombas o equipos similares con solo ajustar las combinaciones específicas de señales. Además, este enfoque modular permite que los modelos entrenados sean interpretables en términos físicos, lo que refuerza su valor diagnóstico en el contexto industrial real.

Variable objetivo **Categoría** **Función en la bomba** **Indicadores de fallo posibles**

Temp_Fase_R_Motor / S / T	Térmica motor	Temperatura por fase del bobinado eléctrico	Desequilibrio de fases, sobreesfuerzo, ventilación deficiente
Int_Fase_R_Motor / S / T	Eléctrica	Intensidad por fase	Carga asimétrica, fallo eléctrico, rozamiento interno
Temp. cojinete acoplamiento / opuesto	Térmica mecánica	Estado térmico de los rodamientos	Fricción, desalineación, desgaste, falta de lubricación
Caudal de descarga de la bomba	Hidráulica	Rendimiento hidráulico general	Cavitación, obstrucción, fallo del rodete

Tabla 3. Resumen variables empleadas en los modelos de predicción. Fuente: Elaboración propia.

5.3 ESTRUCTURA TÉCNICA DEL SISTEMA

Para la implementación del sistema se ha utilizado Python como lenguaje de programación principal, apoyado en librerías especializadas como TensorFlow y Keras para el entrenamiento de modelos de redes neuronales, Pandas y NumPy para el manejo y procesamiento de datos, y Matplotlib para la generación de gráficos de análisis.

La estructura del proyecto se ha organizado de forma modular, con una separación clara por bomba (BOMBA1 y BOMBA2), y dentro de cada una, por fases funcionales: entrenamiento de modelos, cálculo de errores, generación de curvas de estrés, superposición con eventos

de mantenimiento y comparación entre arquitecturas. Esta organización facilita tanto el mantenimiento del código como su reutilización en otros equipos similares.




Figura 6. Estructura de carpetas y archivos del sistema de análisis predictivo implementado. Fuente: Elaboración propia.

Los datos utilizados se presentan en archivos .csv diferenciados por año y por bomba (por ejemplo, df_st21_2020.csv y df_st21_2020_b2.csv), con un formato estandarizado en cuanto a nombres de columnas y estructura temporal. Previamente al uso en modelos, los datos son procesados para eliminar registros nulos y valores atípicos mediante filtros por percentiles, como se documenta en los archivos percentiles_st21.csv y percentiles_st21_bomba2.csv.




Figura 7. Estructura de archivos de datos históricos y scripts de preprocesamiento de datos para entrenamiento de modelos. Fuente: Elaboración propia.

A continuación, una vez se ha estructurado el conjunto de variables de entrada y salida por modelo, los scripts de entrenamiento (`entrenar_modelos_copy.py` y `entrenar_modelos_b2.py`) recorren cada combinación de señales definida en los diccionarios `model_inputs` y `output_columns`. Cada modelo se entrena por separado y se guarda en la carpeta correspondiente (`modelos/`), junto con su historial de entrenamiento y los valores medios y de varianza del error, que posteriormente servirán para establecer los umbrales de detección de anomalías.




Figura 8. Organización de modelos, historiales y archivos de error para la Bomba 1 (Similar para la Bomba 2). Fuente: Elaboración propia.

El conjunto de modelos, curvas de estrés, resultados de predicción, gráficas y configuraciones se almacena de forma ordenada por bomba, por año y por tipo de modelo, lo que asegura la trazabilidad de cada análisis realizado. A su vez, se han generado scripts específicos para la comparación simultánea de curvas y la integración con registros reales de mantenimiento.

La Figura 9 muestra la estructura de carpetas y archivos que componen el sistema desarrollado, así como la organización lógica del flujo de trabajo interno. Los detalles técnicos de cada uno de estos módulos, incluyendo el diseño de los modelos, el tratamiento de errores y la lógica de replicación, se describen en profundidad en las siguientes secciones de este capítulo.




Figura 9. Contenido del repositorio de análisis predictivo para Bomba 1 y Bomba 2. Fuente: Elaboración propia.

Además, resulta importante destacar que la estructura técnica presentada se encuentra directamente alineada con las fases metodológicas definidas en la Figura 4. Cada una de las etapas del diagrama, desde la limpieza de datos, entrenamiento y evaluación de modelos, hasta la comparación cruzada y replicación, ha sido implementada mediante scripts y módulos específicos dentro del sistema. Esta correspondencia asegura una trazabilidad clara entre la planificación conceptual del proyecto y su desarrollo práctico, facilitando la validación del enfoque adoptado y garantizando la coherencia entre la metodología propuesta y su aplicación real sobre los datos industriales.

5.4 IMPLEMENTACIÓN DE MODELOS

La lógica del sistema desarrollado se basa en una comparación entre dos arquitecturas de redes neuronales: redes convolucionales (CNN) y redes LSTM. Ambas arquitecturas han sido entrenadas sobre las variables operativas mencionadas anteriormente, seleccionadas por su relevancia técnica. Esta sección consta de una descripción de cómo se han implementado y entrenado ambos tipos de modelos, el mecanismo utilizado para identificar eventos anómalos y la capacidad del sistema para ser replicado en diferentes máquinas.

5.4.1 MODELOS CNN

Durante la implementación de los modelos CNN se ha definido una arquitectura sencilla pero eficaz para el tratamiento de series temporales multivariadas. Cada modelo toma como entrada una secuencia de 144 pasos consecutivos (equivalente a un día completo si se trabaja con datos cada 10 minutos), lo que permite capturar patrones de evolución más amplios. Estas secuencias se generan mediante la función `create_sequences()`, que transforma automáticamente los datos normalizados en ventanas deslizantes con sus correspondientes etiquetas de predicción.

Antes de la generación de secuencias, los datos son normalizados utilizando la técnica `MinMaxScaler`, aplicada a las variables de entrada de cada modelo para garantizar su

comparabilidad y estabilidad durante el entrenamiento. Esta etapa es fundamental para evitar que las diferencias de magnitud entre señales influyan negativamente en la optimización del modelo.

La arquitectura CNN utilizada está compuesta por las siguientes capas secuenciales:

- Una capa Conv1D con activación ReLU, que actúa como extractor de características sobre la dimensión temporal.
- Una capa MaxPooling1D que reduce la dimensionalidad y evita el sobreajuste concentrando las activaciones más relevantes.
- Una capa GlobalAveragePooling1D que transforma las características extraídas en un vector fijo, independientemente de la longitud de la secuencia.
- Dos capas Dense, siendo la última una neurona lineal que emite la predicción continua del valor esperado de la variable objetivo.

Esta configuración surgió tras un proceso iterativo de prueba y error con diferentes variantes de arquitecturas. Por ejemplo, se evaluaron configuraciones con múltiples capas Conv1D apiladas, lo cual aumentaba la capacidad de extracción de patrones complejos, pero también tendía a sobreajustar los datos al incrementar significativamente el número de parámetros. También se probaron arquitecturas sin la capa GlobalAveragePooling1D, utilizando en su lugar un Flatten, lo cual resultaba en vectores de entrada mucho más grandes para las capas densas y, en consecuencia, modelos más propensos al sobreajuste y con mayor coste computacional.

Se evaluaron además distintas funciones de activación como tanh o elu, pero ReLU mostró un mejor comportamiento en términos de estabilidad durante el entrenamiento y velocidad de convergencia. Finalmente, se experimentó con la eliminación de la capa MaxPooling1D, lo que provocaba una mayor sensibilidad a pequeñas variaciones en los datos temporales, reduciendo la robustez del modelo.

La arquitectura finalmente adoptada representa un equilibrio adecuado entre capacidad de modelado, eficiencia computacional y generalización, lo cual fue validado empíricamente mediante los resultados de validación y las curvas de error obtenidas durante el entrenamiento.

Cada modelo ha sido entrenado de manera individual, utilizando un conjunto específico de variables de entrada y una variable target, tal como se define en los diccionarios `model_inputs` y `output_columns`. Esta configuración garantiza que cada modelo esté adaptado a las relaciones funcionales propias de la variable que predice.

El entrenamiento se aplica mediante validación temporal (sin aleatorización) y se controla con un mecanismo de parada temprana (EarlyStopping) para evitar el sobreajuste. Se emplea el optimizador Adam y la función de pérdida MSE (error cuadrático medio). Cada modelo entrenado se guarda como archivo (.keras), acompañado por su historial de entrenamiento (*_history.json) y por los errores de validación (media y desviación estándar), almacenados en `errores_train.json`.

El script `entrenar_modelos_copy.py` automatiza todo el proceso recorriendo las combinaciones variable-modelo, cargando los datos correspondientes, realizando la normalización, generando las secuencias, construyendo el modelo CNN, y ejecutando su entrenamiento. La versión adaptada para la Bomba 2 (`entrenar_modelos_b2.py`) replica exactamente el flujo, cambiando únicamente las rutas de acceso y los archivos de datos.

Este diseño modular permite mantener separados los modelos por variable y por bomba, facilitando tanto su trazabilidad como su evaluación individual. Además, la ligereza de la arquitectura CNN utilizada la hace especialmente eficiente para el análisis en entornos industriales donde puede ser necesario entrenar múltiples modelos de forma paralela o frecuente.

5.4.2 MODELOS LSTM

Además, el sistema incorpora modelos basados en redes neuronales recurrentes del tipo LSTM (Long Short-Term Memory), diseñadas especialmente para capturar relaciones de

dependencia de largo plazo en series temporales. Estos modelos resultan adecuados para representar la dinámica diaria de las bombas, ya que permiten procesar secuencias largas sin pérdida significativa de información relevante.

Equivalente a los modelos CNN, los modelos LSTM utilizados en este sistema trabajan con secuencias de 144 pasos, lo que equivale a un día completo de operación (considerando 6 muestras por hora durante 24 horas). Esta ventana temporal permite capturar patrones diarios, variaciones lentas y fenómenos que podrían pasar desapercibidos en escalas temporales más reducidas.

Cada modelo LSTM se construye con la siguiente arquitectura:

- Una primera capa LSTM con 64 unidades y retorno de secuencia activado (`return_sequences=True`), lo que permite a la siguiente capa recibir toda la evolución temporal.
- Una segunda capa LSTM con 32 unidades, que sintetiza la información a lo largo del tiempo.
- Una capa Dense final con una sola neurona y activación lineal, responsable de emitir la predicción continua del valor esperado para la variable objetivo.

La arquitectura LSTM finalmente definida es el resultado de una experimentación y ajuste del proceso de construcción para conseguir el mejor modelo posible. Se exploraron diversas configuraciones con el fin de encontrar el equilibrio entre la capacidad predictiva del modelo, su estabilidad durante el entrenamiento y su capacidad de generalización. Inicialmente se probaron modelos simples con una única capa LSTM, que ofrecían una buena eficiencia computacional, pero se mostraban insuficientes para capturar relaciones temporales complejas presentes en las series analizadas.

Posteriormente se evaluaron arquitecturas más profundas, con tres o más capas LSTM, que, aunque incrementaban la capacidad de representación, tendían a sobreajustar, especialmente en casos con conjuntos de datos de tamaño limitado o ruido. También se experimentó con

distintos tamaños de capa, configuraciones como 128-64 ofrecían un rendimiento ligeramente superior en algunos casos, pero a costa de una mayor complejidad y tiempo de entrenamiento. La combinación de 64 unidades en la primera capa (con `return_sequences=True`) y 32 unidades en la segunda capa resultó ser un punto de equilibrio adecuado, permitiendo captar dinámicas temporales amplias y sintetizar dicha información en una representación más compacta.

Asimismo, se analizaron variantes que incluían técnicas de regularización como Dropout o RecurrentDropout, que ayudaban a mitigar el sobreajuste pero introducían inestabilidad en el entrenamiento y no aportaban mejoras sistemáticas en la pérdida de validación. En cuanto a la longitud de las secuencias, se optó por ventanas de 144 pasos (equivalentes a un día de histórico a razón de 10 minutos por muestra), ya que esta duración permitía capturar patrones diarios relevantes sin incrementar innecesariamente la dimensión temporal. Otras decisiones, como el uso de la función de pérdida MSE, el optimizador Adam y la aplicación de EarlyStopping, fueron seleccionadas en base a su buen comportamiento general en tareas de predicción secuencial.

En conjunto, estas decisiones llevaron a una arquitectura final con dos capas LSTM (64 y 32 unidades, respectivamente) seguidas de una capa densa con activación lineal. Esta configuración ha demostrado ser robusta, generalizable y eficiente, justificando su elección frente a otras variantes exploradas durante el desarrollo del proyecto.

El proceso de entrenamiento se gestiona a través del script `entrenar_LSTM.py` (y su equivalente `entrenar_LSTM_b2.py` para la Bomba 2), que automatiza todas las etapas necesarias:

1. La carga y normalización de los datos: los datos se cargan desde los archivos .csv de entrada, se reordenan cronológicamente y se normalizan con `MinMaxScaler` sobre las variables de entrada.

2. La generación de secuencias: se emplea una función que construye ventanas deslizantes de 144 pasos de entrada y una única etiqueta como salida. Cada entrada representa una matriz de $144 \times N$, donde N es el número de variables predictoras.
3. La definición y compilación del modelo: el modelo se construye con Keras, utilizando la función de pérdida MSE (error cuadrático medio) y el optimizador Adam. El sistema también aplica EarlyStopping para evitar sobreentrenamiento.
4. Finalmente, está el entrenamiento y guardado: cada modelo se entrena individualmente por variable y por bomba, y se guarda en la carpeta `modelos_lstm/` con su arquitectura (`.keras`), el historial de entrenamiento (`*_history.json`) y los errores estadísticos del conjunto de referencia (`errores_train_lstm.json`).

Además, el entrenamiento se realiza sin aleatorizar los datos, manteniendo su orden temporal, lo que es crucial para preservar las dependencias causales dentro de las secuencias. Este enfoque permite a los modelos LSTM aprender no solo las relaciones directas entre señales, sino también la forma en que estas evolucionan a lo largo del tiempo.

La estructura modular y flexible del sistema permite adaptar fácilmente la longitud de las ventanas, el número de capas o el tamaño de las unidades LSTM si en el futuro se desea ajustar la arquitectura a otros contextos operativos o volúmenes de datos. En esta implementación se ha optado por un diseño equilibrado que maximiza la capacidad de detección de patrones sin incurrir en un coste computacional elevado.

5.4.3 EXTRACCIÓN DE ERRORES Y EVENTOS ANÓMALOS

Una vez realizado el entrenamiento de los modelos, cada uno es evaluado sobre los datos del mismo año de referencia para calcular el error de predicción en condiciones normales. Este error se analiza estadísticamente, obteniendo su media y desviación estándar. A partir de estos valores se construyen bandas de confianza simétricas de $\pm 2\sigma$ en torno al valor predicho. Si el error de una muestra supera dichos límites, se considera un evento anómalo.

Este proceso se automatiza mediante los scripts `graficasModelos.py` y `graficasModelosLSTM.py` para la Bomba 1, y sus versiones para la Bomba 2. Estos scripts no solo calculan los errores, sino que además generan gráficas que muestran la dispersión de la desviación frente a los límites definidos.

Posteriormente, los eventos anómalos se acumulan en forma de curvas de estrés, generadas mediante los scripts `extraer_curvas_estres.py` y `extraer_curvas_estres_LSTM.py` para la Bomba 1, y sus respectivas variantes para la Bomba 2. Estas curvas, que reflejan el número acumulado de desviaciones fuera de banda, se almacenan en los archivos `curvas_estres.json` y `curvas_estres_lstm.json`, diferenciadas por año y por modelo.

Cabe destacar que, en este proceso, únicamente se han considerado como eventos de estrés peligroso aquellos errores que superan el límite superior de la banda de confianza definida (predicción $+2\sigma$), descartando las desviaciones que quedan por debajo del límite inferior. Esta decisión se fundamenta en la naturaleza operativa de las variables analizadas: en el caso de la temperatura, un valor real inferior al predicho implica que el sistema está funcionando más frío de lo esperado, lo cual no representa una condición crítica; para el caudal, una predicción inferior al valor real tampoco supone un riesgo operativo, mientras que caudales inesperadamente altos pueden reflejar fallos mecánicos o condiciones fuera de especificación; y en el caso de la intensidad eléctrica, una menor demanda no es problemática, pero un consumo superior al estimado puede indicar sobrecarga o deterioro. Por tanto, el criterio adoptado prioriza la detección de incrementos anómalos en las variables, al ser estos los que verdaderamente pueden comprometer la integridad del sistema.

Estas curvas se representan gráficamente y permiten observar de manera visual la evolución del estrés operativo a lo largo del tiempo. Para facilitar su interpretación en contexto, se incorporan sobre las gráficas las fechas reales en las que se realizaron tareas de mantenimiento, de modo que sea posible analizar si los incrementos en el estrés detectado por los modelos preceden o coinciden con intervenciones técnicas. Esta superposición permite evaluar el potencial predictivo del sistema y su utilidad como herramienta de apoyo en la planificación del mantenimiento.

5.4.4 ESCALABILIDAD Y REPLICACIÓN

Una de las características más relevantes del sistema es su capacidad de replicación, ya que todo el flujo descrito ha sido duplicado para la segunda bomba de agua de circulación, utilizando sus datos independientes y adaptando mínimamente los scripts de código. Esta réplica funcional ha requerido únicamente ajustes en las rutas de datos y, en algunos casos, en el nombre de ciertas columnas específicas.

La replicación completa del sistema ha dado lugar a la verificación de que la metodología no está sobre ajustada a un único equipo, sino que es posible aplicarla de forma directa a otro activo. Esta escalabilidad está garantizada por el diseño modular del código y por la generalización de los diccionarios de configuración de modelos. Además, en el script final de comparación de desviación acumulada de ambos modelos para ambas bombas, se consigue representar simultáneamente todas las curvas y contrastar su evolución en paralelo, reforzando así la validación cruzada de la herramienta.

En resumen, esta estructura permite que el sistema no solo funcione de forma autónoma y precisa, sino que también esté preparado para extenderse a nuevos equipos sin necesidad de redefinir la lógica de análisis ni las estructuras de modelado.

Capítulo 6. ANÁLISIS DE RESULTADOS

En el siguiente capítulo se recogen los resultados obtenidos tras la evaluación de los modelos CNN y LSTM aplicados a las bombas de agua de circulación del estudio. Estas desviaciones son analizadas entre los valores reales y los predichos de los modelos, clasificando los errores detectados en función de su magnitud y evolución temporal. Las gráficas de error permiten identificar eventos fuera de banda ($\pm 2\sigma$) que pueden interpretarse como señales tempranas de deterioro o funcionamiento anómalo.

El análisis se organiza en torno a dos bloques principales, la Bomba 1 y la Bomba 2. En cada uno se diferencian los resultados obtenidos por los modelos CNN y LSTM. Finalmente, se presenta una sección dedicada a la comparación cruzada entre bombas mediante curvas de desviación acumulada.

6.1 GRÁFICAS DE ERROR: BOMBA 1

6.1.1 MODELOS CNN

En los modelos CNN aplicados a la Bomba 1 se observa un rendimiento robusto durante los años de entrenamiento (2020 o 2021 según la variable), con desviaciones generalmente contenidas dentro de los umbrales establecidos. Sin embargo, a medida que se avanza en el tiempo, comienzan a aparecer patrones anómalos sostenidos en varias señales.

- En el modelo de caudal de descarga, se aprecia un aumento significativo de las desviaciones fuera de banda a partir de 2022, con picos claramente acumulados en 2023. Esta evolución sugiere una pérdida progresiva de rendimiento hidráulico.





Figura 10. Desviación del modelo CNN aplicado a la variable de caudal de descarga de la Bomba 1 en distintos años. Fuente: Elaboración propia.

- Las intensidades en las fases R, S y T presentan un comportamiento estable en 2020 y 2021, pero en 2022 se detectan secuencias de errores consecutivos que apuntan a desequilibrios eléctricos o cargas irregulares.







Figura 11. Desviaciones del modelo CNN para intensidades eléctricas en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.

- Las temperaturas del motor por fase muestran un patrón diferente: las desviaciones tienden a dispersarse, sin acumulaciones abruptas, aunque se observa un leve aumento de la variabilidad en años posteriores.






Figura 12. Desviaciones del modelo CNN para temperaturas del motor en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.

- Las temperaturas de cojinetes destacan por la persistencia de las desviaciones, especialmente en los años 2022 y 2023. Estos modelos presentaron una particularidad durante su desarrollo: inicialmente fueron entrenados, como el resto, utilizando datos del año 2020 como referencia. Sin embargo, al analizar los resultados, se observó que las desviaciones durante 2020 eran notablemente más elevadas que en 2021, lo cual contradecía la expectativa de una evolución progresiva del deterioro. Esta anomalía llevó a revisar el historial de mantenimiento, descubriéndose que se había realizado una intervención relevante justo antes del inicio de 2021. Por este motivo, se decidió reentrenar los modelos utilizando 2021 como año de referencia, permitiendo así una comparación más coherente con los años posteriores. Las gráficas resultantes muestran un deterioro progresivo y mantenido a partir de 2021, con desviaciones cada vez más frecuentes fuera de los límites de tolerancia, especialmente en 2022 y 2023.




Figura 13. Desviaciones del modelo CNN para temperaturas de cojinete de la Bomba 1 (2020–2023).

Fuente: Elaboración propia.

6.1.2 MODELOS LSTM

Los modelos LSTM para la Bomba 1 muestran una sensibilidad mayor frente a las variaciones suaves y tendencias de largo plazo, lo que se refleja en un mayor número de desviaciones detectadas respecto a las CNN.

- En el caso del caudal de descarga, el modelo LSTM es capaz de detectar antes los aumentos de desviación observados también por la CNN, lo que confirma su capacidad para identificar el deterioro de forma anticipada.

Desviaciones por Año - Caudal_Descarga_model





Figura 14. Desviación del modelo LSTM para caudal de descarga por año (2020–2023) de la Bomba 1.


Fuente: Elaboración propia.

- Para las intensidades por fase, las LSTM presentan errores más dispersos, pero muestran picos anticipados respecto a los modelos convolucionales. Esto podría indicar una mayor sensibilidad ante fluctuaciones de carga.

Desviaciones por Año - Int_Fase_R_model



Desviaciones por Año - Int_Fase_S_model



Desviaciones por Año - Int_Fase_T_model






Figura 15. Desviaciones del modelo LSTM para intensidades eléctricas en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.

- En las temperaturas de fase del motor, el patrón se repite. Se observan más puntos fuera de banda, aunque de menor magnitud, reflejando una detección más temprana pero también más propensa a falsos positivos.

Desviaciones por Año - Temp_Fase_R_model



Desviaciones por Año - Temp_Fase_S_model



Desviaciones por Año - Temp_Fase_T_model





Figura 16. Desviaciones del modelo CNN para temperatura del motor en fases R, S y T de la Bomba 1 (2020–2023). Fuente: Elaboración propia.

- Las temperaturas de cojinetes revelan desviaciones amplias y sostenidas, con mayor claridad que en los modelos CNN. En 2023, las predicciones divergen fuertemente del comportamiento real, lo que respalda la utilidad diagnóstica de estas variables.

Desviaciones por Año - Temperatura_Cojinete_ModelCC22



Desviaciones por Año - Temperatura_Cojinete_ModelCC21




Figura 17. Desviaciones del modelo LSTM para temperaturas de cojinete de la Bomba 1 (2020–2023).

Fuente: Elaboración propia.

6.2 GRÁFICAS DE ERROR: BOMBA 2

6.2.1 MODELOS CNN

La aplicación de los modelos CNN a la Bomba 2 reproduce muchos de los patrones observados en la Bomba 1, lo que confirma la capacidad del sistema para generalizar a otras máquinas con configuraciones similares.

- El caudal de descarga vuelve a ser una de las señales más reveladoras. En este caso, se observa una progresión más lineal del deterioro, con errores crecientes, pero sin picos tan abruptos como en la Bomba 1.

Desviaciones por Año - Caudal_Descarga_model





Figura 18. Desviación del modelo CNN para caudal de descarga por año (2020–2023) de la Bomba 2.


Fuente: Elaboración propia.

- Las intensidades eléctricas presentan un patrón más ruidoso, con bloques enteros de errores elevados en años como 2021 y 2022. Esto sugiere posibles problemas eléctricos recurrentes o desequilibrios persistentes.

Desviaciones por Año - Int_Fase_R_model



Desviaciones por Año - Int_Fase_S_model



Desviaciones por Año - Int_Fase_T_model






Figura 19. Desviaciones del modelo CNN para intensidades eléctricas en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.

- Las temperaturas de fase se comportan de manera estable, aunque presentan una dispersión algo mayor que en la Bomba 1, lo cual podría reflejar condiciones de operación más variables.

Desviaciones por Año - Temp_Fase_R_model



Desviaciones por Año - Temp_Fase_S_model



Desviaciones por Año - Temp_Fase_T_model





Figura 20. Desviaciones del modelo CNN para temperatura del motor en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.

- En los modelos de temperatura de cojinetes, los errores detectados confirman una evolución sostenida del deterioro, con desviaciones muy significativas a lo largo del año 2023.

Desviaciones por Año - Temperatura_Cojinete_ModelCC21



Desviaciones por Año - Temperatura_Cojinete_ModelCC22




Figura 21. Desviaciones del modelo CNN para temperaturas del cojinete de la Bomba 2 (2020–2023).

Fuente: Elaboración propia.

6.2.2 MODELOS LSTM

Los modelos LSTM sobre la Bomba 2 confirman su sensibilidad para detectar señales de deterioro anticipadamente.

- Para el caudal de descarga, se observa una acumulación progresiva de errores ya desde 2021, con patrones que se intensifican hacia 2023.

Desviaciones por Año - Caudal_Descarga_model





Figura 22. Desviación del modelo LSTM para caudal de descarga por año (2020–2023) de la Bomba 2.


Fuente: Elaboración propia.

- En las intensidades por fase, la LSTM permite visualizar claramente momentos de carga anómala, con secuencias de desviación que reflejan estrés eléctrico o condiciones operativas desfavorables.

Desviaciones por Año - Int_Fase_R_model



Desviaciones por Año - Int_Fase_S_model



Desviaciones por Año - Int_Fase_T_model






Figura 23. Desviaciones del modelo LSTM para intensidades eléctricas en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.

- Las temperaturas del motor vuelven a mostrar una mayor variabilidad, con errores contenidos pero sostenidos en los años finales.

Desviaciones por Año - Temp_Fase_R_model



Desviaciones por Año - Temp_Fase_S_model



Desviaciones por Año - Temp_Fase_T_model





Figura 24. Desviaciones del modelo LSTM para temperaturas del motor en fases R, S y T de la Bomba 2 (2020–2023). Fuente: Elaboración propia.

- Finalmente, en los cojinetes, las curvas LSTM muestran el mayor nivel de desviación detectado entre todas las variables y modelos, especialmente en 2023, consolidando esta variable como la de mayor valor predictivo.

Desviaciones por Año - Temperatura_Cojinete_ModelCC22



Desviaciones por Año - Temperatura_Cojinete_ModelCC21




Figura 25. Desviaciones del modelo LSTM para temperaturas del cojinete de la Bomba 2 (2020–2023).

Fuente: Elaboración propia.

6.3 GRÁFICAS DE COMPARACIÓN DE LA DESVIACIÓN ACUMULADA:

Este estudio se realiza con el objetivo de analizar y comparar el comportamiento de dos modelos de predicción, CNN y LSTM, aplicados al monitoreo de dos bombas (B1 y B2), utilizando como métrica la desviación acumulada fuera de banda. Esta métrica se define como la suma acumulativa, a lo largo del tiempo, de aquellas desviaciones entre las predicciones del modelo y los valores reales que exceden un umbral considerado representativo del funcionamiento normal del sistema. Este umbral se establece con la expresión: $\text{banda superior} = \text{MAE} + 2 \times \text{STD}$, donde MAE es el error absoluto medio obtenido durante el entrenamiento del modelo, y STD es la desviación estándar de dicho error. Al considerar únicamente las predicciones que superan este límite, se identifica cuándo el modelo detecta comportamientos anómalos o potenciales procesos de degradación. La acumulación de estas desviaciones permite detectar valores fuera de lo esperado y evaluar también su persistencia y evolución en el tiempo, lo cual es fundamental para anticipar fallos antes de que se materialicen.

En las gráficas generadas se representan las curvas de desviación acumulada de ambos modelos para las dos bombas. Las líneas empleadas tienen el siguiente significado:

- Línea azul continua: modelo CNN aplicado a la bomba B1
- Línea verde continua: modelo LSTM aplicado a la bomba B1
- Línea azul discontinua: modelo CNN aplicado a la bomba B2
- Línea verde discontinua: modelo LSTM aplicado a la bomba B2

Además de las curvas, se han incorporado líneas verticales que marcan eventos de mantenimiento reales, extraídos del historial técnico de las instalaciones. Estas líneas son un componente clave del análisis, ya que permiten contextualizar el comportamiento de los

modelos frente a las intervenciones físicas realizadas sobre los equipos. Las líneas verticales se representan de la siguiente manera:

- Línea roja: mantenimiento correctivo en la bomba B1
- Línea azul: mantenimiento preventivo en la bomba B1
- Línea naranja: mantenimiento correctivo en la bomba B2
- Línea morada: mantenimiento preventivo en la bomba B2

Las marcas temporales mencionadas actúan como referencias visuales que facilitan la interpretación de las curvas de desviación acumulada. Por ejemplo, en múltiples casos se observa que, una vez se ha realizado una intervención tanto correctiva como preventiva, la pendiente de la curva se reduce o se estabiliza, sugiriendo que el modelo estaba captando correctamente un deterioro previo al mantenimiento. Al mismo tiempo, se detectan situaciones en las que la curva empieza a aumentar significativamente antes de que se haya registrado una intervención, lo que puede considerarse como una detección temprana de fallo o de desviación progresiva del funcionamiento esperado. De esta manera, incluir las líneas verticales de mantenimiento aporta contexto histórico y refuerza la utilidad de esta métrica como apoyo en estrategias de mantenimiento predictivo y planificación de intervenciones.

Respecto al análisis comparado entre bombas, en términos generales se observa que la bomba B1 muestra un comportamiento más estable y con menor acumulación de desviaciones en casi todos los modos de fallo considerados. Esta diferencia sugiere una condición operativa más favorable en B1, bien sea por menor desgaste, un entorno de operación más estable o intervenciones de mantenimiento más eficaces y oportunas.

Al comparar los modelos CNN y LSTM, se evidencian diferencias notables en diferentes escenarios. Los modelos LSTM tienden a ser más sensibles a desviaciones progresivas, acumulando errores cuando se detectan patrones de deriva temporal. Por otro lado, los modelos CNN muestran más reactividad frente a cambios abruptos o picos puntuales, pero tienden a acumular menos desviaciones cuando el deterioro se produce de forma gradual.

Esta diferencia metodológica puede explicar por qué, ante las mismas variables y condiciones, ambos modelos generan perfiles de desviación acumulada significativamente distintos.

Este comportamiento se analiza en detalle a través de las siguientes gráficas:




Figura 26. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Caudal de descarga. Fuente: Elaboración propia.

El modelo CNN aplicado a la bomba B2 presenta un aumento muy significativo de la desviación acumulada a partir de 2022, reflejando varios episodios abruptos o fugas repentinas. La curva correspondiente al modelo LSTM también crece, pero de forma más progresiva. En la bomba B1, ambas curvas se mantienen bajas. Las líneas verticales que aparecen en esta figura muestran múltiples mantenimientos correctivos y preventivos realizados tanto en B1 como en B2. En particular, las líneas rojas y naranjas de B2 se alinean con los aumentos de desviación del modelo CNN, lo que sugiere que las intervenciones respondieron a problemas detectados por este modelo. En cambio, en B1 los mantenimientos aparecen sin que las curvas indiquen un comportamiento anómalo significativo, lo que refuerza la idea de una bomba en mejor estado.

Esta diferencia tan marcada en la curva del modelo CNN de la bomba 2 se debe probablemente a particularidades propias de los datos de esa bomba, más que a diferencias

en el entrenamiento, ya que ambos modelos fueron entrenados de forma idéntica y con datos del mismo año (2020). Lo más probable es que las señales medidas en la bomba 2 presenten mayor variabilidad, ruido o valores fuera de rango más frecuentes, lo que hace que el modelo CNN reaccione con más sensibilidad ante desviaciones durante los años de evaluación. Además, si bien los sensores son conceptualmente equivalentes, pequeñas diferencias en el comportamiento operativo, la calidad del dato o el escalado real pueden hacer que el modelo interprete ciertos patrones como anómalos más fácilmente. Esto explicaría por qué el riesgo acumulado del modelo de caudal en la bomba 2 aparece significativamente más alto que en el resto.




Figura 27. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase R. Fuente: Elaboración propia.

Aquí, el modelo LSTM aplicado a B2 acumula más errores que el CNN, indicando una sensibilidad mayor ante una deriva prolongada en esta señal. No se observan líneas de mantenimiento asociadas a este modelo o variable en esa bomba, lo que indica que este patrón no fue diagnosticado como fallo en campo, o que no afectó directamente a los componentes controlados en los mantenimientos registrados.

Esta mayor acumulación de desviación en el modelo LSTM para la bomba 2 podría deberse a que este tipo de red, al estar diseñada para capturar dependencias temporales, es más sensible a cambios lentos y sostenidos en la señal, como los que produce una deriva

progresiva. Es posible que en la bomba 2 haya habido una alteración gradual en la variable de intensidad que no llegó a un umbral considerado crítico por el personal de mantenimiento, pero que el LSTM sí detectó como una desviación sistemática respecto al comportamiento aprendido en 2020. Esta diferencia respecto al CNN, que muestra una curva más estable, puede indicar que el LSTM está captando un cambio de tendencia de largo plazo que el CNN, por su arquitectura más localizada y menos contextual, tiende a ignorar o a considerar como parte del ruido normal.



Figura 28. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase S. Fuente: Elaboración propia.

Ambos modelos aplicados a la bomba B2 presentan acumulaciones relevantes. El modelo LSTM muestra una pendiente más continua durante 2023, lo que puede reflejar un proceso de deterioro progresivo. En este caso, no se identifican líneas verticales que coincidan con esos aumentos, lo que sugiere que los mantenimientos realizados no estuvieron directamente relacionados con esta señal, o que el deterioro aún no se había manifestado de forma evidente en campo.




Figura 29. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable Intensidad fase T. Fuente: Elaboración propia.

El modelo LSTM para B2 alcanza un nivel muy alto de desviación acumulada, frente a un modelo CNN con comportamiento casi plano. No hay eventos de mantenimiento marcados, lo que indicaría que esta anomalía no fue detectada por el personal o no fue considerada relevante durante el periodo cubierto. Esto puede interpretarse como un valor añadido del modelo LSTM para anticipar problemas que aún no se traducen en fallos manifiestos.




Figura 30. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase R. Fuente: Elaboración propia.

Los modelos se comportan de forma similar, aunque CNN en B2 muestra una mayor acumulación puntual. Se observan líneas moradas y naranjas en fechas posteriores a los picos de CNN, lo cual sugiere que ese modelo fue capaz de detectar de forma temprana ciertos síntomas que finalmente derivaron en intervención técnica.




Figura 31. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase S. Fuente: Elaboración propia.

CNN en B2 vuelve a registrar más desviación acumulada que LSTM. Se observan líneas verticales correctivas posteriores, que refuerzan la idea de que CNN captó bien una alteración puntual de la señal.




Figura 32. Comparación de la desviación acumulada resultante de CNN vs LSTM para la variable temperatura fase T. Fuente: Elaboración propia.

En esta señal, CNN sobre B1 presenta una desviación acumulada más alta que LSTM. Se marcan eventos de mantenimiento sobre B1, pero en fechas algo posteriores que no están visibles. La anticipación del modelo CNN podría haber motivado una revisión que evitó mayores daños.




Figura 33. Comparación de la desviación acumulada resultante de CNN vs LSTM para las variables Temperatura del Cojinete. Fuente: Elaboración propia.

Los modelos LSTM para B2 presentan acumulaciones importantes, sobre todo a partir de 2023. Esto se corresponde con varios mantenimientos registrados (líneas naranjas y moradas), que confirman que los síntomas detectados por el modelo tuvieron impacto real sobre el funcionamiento del sistema. CNN, por su parte, acumula menos desviaciones en estas variables, lo cual puede reflejar una menor sensibilidad a los cambios térmicos de baja pendiente.

En resumen, la presencia de líneas verticales próximas a un aumento en la acumulación de errores refuerza el valor de los modelos como herramienta de anticipación, ya que sugiere que lograron detectar comportamientos anómalos antes de que se realizara una intervención de mantenimiento. Por el contrario, cuando no se observan líneas asociadas, puede deberse a que la anomalía detectada no fue considerada crítica en campo, no fue diagnosticada como un fallo relevante, o simplemente no estaba vinculada a componentes incluidos en la planificación del mantenimiento. También es posible que algunas señales, como las eléctricas o térmicas, no hayan generado alertas operativas claras, a pesar de mostrar desviaciones desde el punto de vista del modelo.

Por todo ello, es esencial no interpretar las curvas de forma aislada, sino en conjunto con el historial de mantenimiento y el conocimiento del sistema, para tomar decisiones informadas y orientar correctamente las políticas de supervisión predictiva.

Modo de fallo / Variable	Bomba con menos estrés	Modelo más sensible	Diferencia más modelos	Recomendación
Caudal de descarga	B1	CNN	CNN detecta picos abruptos en B2, LSTM más estable	CNN para detección de eventos repentinos

Intensidad fase R	B1	LSTM	LSTM acumula más desviaciones en B2 por deriva	LSTM adecuado para cambios graduales
Intensidad fase S	B1	Ambos	Ambos acumulan en B2, LSTM con pendiente sostenida	LSTM mejor para monitoreo continuo
Intensidad fase T	B1	LSTM	LSTM detecta deterioro progresivo que CNN ignora	LSTM para síntomas lentos
Temperatura fase R	B1	CNN	CNN muestra picos puntuales, LSTM más plano	CNN útil si hay eventos térmicos bruscos
Temperatura fase S	B1	CNN	CNN acumula en B2, LSTM se mantiene bajo	CNN adecuado ante aumentos localizados
Temperatura fase T	B2	CNN	CNN detecta más en B1, LSTM más estable	Depende de la ubicación de la bomba

Temperatura cojinete radial (CC21)	B1	LSTM	LSTM acumula más desde 2023 en B2	LSTM útil para seguimiento térmico sostenido
Temperatura cojinete radial (CC22)	B1	LSTM	LSTM más reactivo ante deriva prolongada	LSTM recomendable si se busca anticipación térmica

Tabla 4. Tabla resumen de los resultados. Fuente: Elaboración propia.

En conclusión, los resultados muestran que los modelos CNN y LSTM capturan distintos tipos de desviaciones, mientras que CNN es más eficaz ante anomalías puntuales y abruptas, LSTM destaca en la detección de patrones de degradación progresiva. La bomba B1 presenta un comportamiento más estable en la mayoría de los modos de fallo, lo que refuerza la fiabilidad de sus predicciones. La diferencia entre modelos, pese a usar las mismas señales, responde a sus arquitecturas, ya que CNN prioriza la respuesta local, y LSTM la evolución temporal. Por ello, la elección del modelo más adecuado debe basarse en el tipo de fallo esperado, siendo recomendable un enfoque complementario que combine ambos para una supervisión más robusta y anticipativa.

Capítulo 7. CONCLUSIONES Y TRABAJOS FUTUROS

Durante este trabajo se ha desarrollado un sistema de mantenimiento predictivo basado en modelos de aprendizaje profundo, específicamente redes neuronales convolucionales (CNN) y redes LSTM, aplicados al análisis de bombas de agua de circulación en un entorno industrial real. A lo largo del trabajo se ha implementado una metodología completa que abarca desde la recopilación, limpieza y análisis de datos históricos hasta el entrenamiento, evaluación y comparación de modelos. Se ha prestado especial atención a la generación de curvas de desviación acumulada como herramienta diagnóstica y al contraste de estas con eventos reales de mantenimiento registrados en planta. Esta metodología se ha aplicado a dos bombas equivalentes, validando la escalabilidad del sistema y su capacidad para adaptarse a condiciones operativas distintas.

Los objetivos definidos al inicio del proyecto se han alcanzado satisfactoriamente. Se ha conseguido construir un sistema que es capaz de identificar desviaciones significativas respecto al comportamiento nominal de variables clave del sistema, anticipando fallos inesperados antes de que ocurran. De la misma manera, se ha realizado una comparación detallada entre los modelos CNN y LSTM, evidenciando cómo cada uno presenta ventajas específicas en función del tipo de síntoma a detectar. Además, se ha demostrado la utilidad práctica de contextualizar las curvas de estrés con los mantenimientos reales, lo cual ha permitido evaluar la eficacia de las intervenciones realizadas y detectar casos en los que se actuó de forma anticipada o, por el contrario, se dejó evolucionar un deterioro sin respuesta.

Desde el punto de vista analítico, una de las principales conclusiones del trabajo es la complementariedad de los modelos estudiados. Mientras que las CNN muestran una respuesta más eficaz ante anomalías abruptas o desviaciones puntuales, los modelos LSTM captan mejor los procesos de degradación lenta y progresiva. Esta diferencia metodológica pone de manifiesto que no existe un único modelo óptimo, sino que la arquitectura más adecuada dependerá del tipo de variable, del modo de fallo que se pretenda detectar y del horizonte temporal de análisis. Además, el contraste entre ambas bombas ha evidenciado

que el comportamiento del sistema no depende exclusivamente del modelo aplicado, sino también del historial operativo, de las condiciones de servicio y de la eficacia de las intervenciones previas.

Como líneas de trabajo futuras, se plantea la integración de modelos híbridos CNN-LSTM que combinen la capacidad de detectar patrones locales con la sensibilidad a las dependencias temporales de largo plazo. Asimismo, podría ampliarse el conjunto de variables consideradas incorporando señales como vibraciones, consumo energético o condiciones ambientales, lo que permitiría cubrir nuevos modos de fallo y enriquecer el diagnóstico del sistema. Otra posible evolución del sistema consiste en implementar módulos de estimación de vida útil remanente (RUL), que permitan no solo detectar una anomalía, sino predecir cuánto tiempo queda antes de que se alcance una condición crítica. Por último, se recomienda trabajar en la mejora de la interpretabilidad de los modelos, facilitando que los técnicos de planta comprendan las razones detrás de una alerta o predicción, y aumentando así la confianza en el uso operativo del sistema.

En definitiva, este trabajo ha demostrado que es posible aplicar técnicas avanzadas de aprendizaje automático a problemas reales de mantenimiento industrial, obteniendo resultados valiosos tanto desde un punto de vista técnico como operativo. Las herramientas desarrolladas no solo permiten anticipar fallos, sino también comprender su evolución, contextualizarlos con el historial de la instalación y tomar decisiones más informadas sobre cuándo y cómo intervenir. Esta aproximación representa un paso firme hacia una gestión más eficiente, predictiva y basada en datos del mantenimiento industrial.

Capítulo 8. ALINEACIÓN DEL TRABAJO CON LOS ODS

El presente trabajo, basado en el desarrollo de un sistema de mantenimiento predictivo centrado en técnicas de aprendizaje automático, se alinea de manera directa con múltiples Objetivos de Desarrollo Sostenible (ODS) establecidos por la Agenda 2030 de Naciones Unidas. Con la mejora de la eficiencia operativa, la reducción del desperdicio de recursos técnicos y el impulso de soluciones digitales sostenibles en entornos industriales se contribuye a un modelo más responsable e innovador. A continuación, se detallan los ODS con los que el proyecto se identifica.



Figura 34. Objetivos de desarrollo sostenible. Fuente: Organización de las Naciones Unidas [25].

ODS 7: Energía asequible y no contaminante

Uno de los efectos indirectos del sistema desarrollado es la optimización del consumo energético en los equipos industriales supervisados. Variables como la intensidad por fase del motor o el caudal de descarga son indicadores clave del rendimiento energético de una bomba. Con la detección de fallos incipientes mediante los modelos predictivos, se habilita la corrección anticipada del problema, lo que resulta en menos consumo eléctrico a medio plazo. Esta reducción en el uso innecesario de energía mejora la eficiencia y contribuye a disminuir las emisiones derivadas del consumo energético en planta.

ODS 9: Industria, innovación e infraestructura

El sistema representa una gran aportación al objetivo de fomentar una industrialización más sostenible mediante la innovación tecnológica. La introducción de redes neuronales (CNN y LSTM) aplicadas a señales industriales reales constituye una estrategia de innovación orientada a aumentar la fiabilidad de los equipos y a reducir costes de mantenimiento. Al permitir una supervisión inteligente del estado de los activos, el sistema refuerza la resiliencia de las infraestructuras industriales y promueve la transformación digital del mantenimiento, uno de los ejes fundamentales de la industria 4.0.

ODS 12: Producción y consumo responsables

La incorporación de mantenimiento predictivo como práctica habitual en la gestión de activos industriales contribuye a una utilización más eficiente de los recursos. Evitar averías mediante la detección temprana del deterioro reduce el consumo innecesario de repuestos, aceite, energía, mano de obra y componentes. Además, prolongar la vida útil de los equipos se traduce en menos generación de residuos industriales y menor necesidad de fabricar o transportar nuevos recambios. Todo ello apoya un modelo de producción más sostenible y ajustado a criterios de economía circular.

ODS 13: Acción por el clima

Además, el proyecto también se alinea con los objetivos relacionados con la lucha contra el cambio climático, de manera indirecta. Esto es debido a que el uso de inteligencia artificial para prever y mitigar fallos técnicos reduce el impacto ambiental de los procesos de

mantenimiento, por ejemplo, se minimizan las paradas de emergencia, los desplazamientos urgentes de equipos técnicos y la reposición innecesaria de componentes. Esta mayor eficiencia global repercute en una menor huella de carbono, tanto en términos energéticos como logísticos.

En conclusión, este trabajo no solo presenta una aportación tecnológica a nivel de modelado predictivo, sino que se sitúa también dentro del marco global de los ODS, promoviendo un uso más inteligente y sostenible de los recursos industriales. La integración de técnicas de inteligencia artificial en la operativa real refuerza el papel de la ingeniería como herramienta clave para la sostenibilidad y el desarrollo industrial responsable.

Capítulo 9. BIBLIOGRAFÍA

- [6] 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*, 495, 012067. <https://doi.org/10.1088/1757-899X/495/1/012067>
- [7] Wang, Q., Bu, S., & He, Z. (2020). Achieving predictive and proactive maintenance for high-speed railway power equipment with LSTM-RNN. *IEEE Transactions on Industrial Informatics*, 16(10), 6509–6516. <https://doi.org/10.1109/TII.2020.2966033>
- [8] Kim, D.-G., & Choi, J.-Y. (2021). Optimization of design parameters in LSTM model for predictive maintenance. *Applied Sciences*, 11(14), 6450. <https://doi.org/10.3390/app11146450>
- [9] Silva, W., & Capretz, M. (2019). Assets predictive maintenance using convolutional neural networks. In *SNPD 2019 – 20th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing* (pp. 59–66). IEEE. <https://doi.org/10.1109/SNPD.2019.8935752>
- [10] De Vita, F., & Bruneo, D. (2019). On the use of LSTM networks for predictive maintenance in smart industries. In *2019 IEEE International Conference on Smart Computing (SMARTCOMP)* (pp. 241–248). IEEE. <https://doi.org/10.1109/SMARTCOMP.2019.00059>
- [11] Chhabria, S., Ghata, R., Mehta, V., Ghosekar, A., Araspure, M., & Pakhide, N. (2022). Predictive maintenance using machine learning on industrial water pumps. *International Journal of Innovations in Engineering and Science*, 7(9), 76–81. <https://doi.org/10.46335/IJIES.2022.7.9.16>
- [12] Nasser, A., & Al-Khazraji, H. (2022). A hybrid of convolutional neural network and long short-term memory network approach to predictive maintenance. *International Journal of Electrical and Computer Engineering*, 12(1), 721–730. <https://doi.org/10.11591/ijece.v12i1.pp721-730>
- [13] Loeffler, B. (2011). Cloud computing: What is infrastructure as a service. *Microsoft Technet Magazine*, October 2011. <https://technet.microsoft.com/en-us/magazine/hh509051.aspx>
- [14] Olesen, J. F., & Shaker, H. R. (2020). Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges. *Sensors*, 20(8), 2425. <https://doi.org/10.3390/s20082425>

- [15] Jardine, A. K. S., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483–1510. <https://doi.org/10.1016/j.ymssp.2005.09.012>
- [16] Carranza, A. A., & Medina, A. J. (2023). Impacto de la inteligencia artificial en la gestión de mantenimiento predictivo en la industria. *Iberotec: Revista de Ciencia y Tecnología*, 4(2), 47–59. <https://doi.org/10.56183/iberotecs.v4i2.644>
- [17] Sanz-Bobi, M. A., Orbach, S., Bellido-López, F. J., Muñoz, A., Gonzalez-Calvo, D., & Alvarez-Tejedor, T. (2024). Anomaly detection of a cooling water pump of a power plant based on its virtual digital twin constructed with deep learning techniques. *Proceedings of the 8th European Conference of the Prognostics and Health Management Society 2024*. <https://doi.org/10.36001/phme.2024.v8i1.4004>
- [18] L. Yang, X. Ma, R. Peng, Q. Zhai, and Y. Zhao. A preventive maintenance policy based on dependent two-stage deterioration and external shocks. *Reliability Engineering and System Safety*, vol. 160, no. May 2016, pp. 201–211, 2017. <https://doi.org/10.1016/j.ress.2016.12.008>
- [19] Bartolomé Aramburu, R. (2018). *Mantenimiento predictivo de los equipos industriales mediante el uso de la inteligencia artificial* [Trabajo de Fin de Grado, Universitat Politècnica de Catalunya]. Repositorio institucional UPC. <https://upcommons.upc.edu/handle/2117/167239>
- [20] Benavente Álvarez, R. A. (2024). *Predicción del deterioro en bombas multietapa mediante aprendizaje automático supervisado usando Random Forest* [Tesis de licenciatura, Universidad Nacional del Altiplano]. Repositorio Institucional UNAP. <https://repositorio.unap.edu.pe/handle/20.500.14082/23859>
- [21] Wu, H., Huang, A., & Sutherland, J. W. (2020). Avoiding environmental consequences of equipment failure via an LSTM-based model for predictive maintenance. *Procedia Manufacturing*, 43, 666–673. <https://doi.org/10.1016/j.promfg.2020.02.131>
- [22] MathWorks. (s.f.). ¿Qué es una red neuronal convolucional? <https://es.mathworks.com/discovery/convolutional-neural-network.html>
- [23] DataScientest. (2023). *Memoria a largo plazo y a corto plazo: LSTM*. <https://datascientest.com/es/memoria-a-largo-plazo-a-corto-plazo-lstm>
- [24] Hochreiter, S., & Schmidhuber, J. (1997). *Long Short-Term Memory*. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- [25] Organización de las Naciones Unidas. (2015). *La Asamblea General adopta la Agenda 2030 para el Desarrollo Sostenible*. <https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/>

ANEXO I:

APPENDIX I: Código del Proyecto

El código del proyecto se mantiene privado a efectos de publicación, pero se facilitará a los miembros autorizados del comité de corrección y de la empresa colaboradora si lo solicitan con fines de reproducibilidad.