



MEMORIA DE ACTIVIDADES 23 25

CÁTEDRA
APLICACIONES DE LA IA
AL MANTENIMIENTO
BASADO EN DATOS



endesa

23 MEMORIA DE ACTIVIDADES 25

CÁTEDRA
APLICACIONES DE LA IA
AL MANTENIMIENTO
BASADO EN DATOS



TABLA DE CONTENIDO

1	CREACIÓN DE LA CÁTEDRA DE APLICACIONES DE LA INTELIGENCIA ARTIFICIAL AL MANTENIMIENTO BASADO EN DATOS	7
2	OBJETIVOS Y ALCANCE DE LA CÁTEDRA	9
3	CONTEXTO DE TRABAJO	11
4	TIPOS DE ACTIVIDADES REALIZADAS	13
5	ACTIVIDADES DE INVESTIGACIÓN APLICADA	15
5.1	DIAGNÓSTICO DE COMBUSTIÓN EN TURBINAS DE GAS MEDIANTE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO	15
5.1.1	Introducción	15
5.1.2	Estado del arte	15
5.1.3	Combustión de la turbina de gas y métodos de detección de fallo	17
5.1.4	Ensemble de modelos de machine learning para la detección de anomalías	18
5.1.5	Resultados	25
5.1.6	Ensemble y resultado final	35
5.1.7	Conclusiones	37
5.1.8	Referencias	39
5.2	GMTWIN: ANÁLISIS PREDICTIVO DE FALLOS EN EQUIPOS	41
5.2.1	Presentación y objetivos de la Fase 1	42
5.2.2	Metodología	42
5.2.3	Caso de estudio	49
5.2.4	Conclusiones	60
5.2.5	Referencias	61
5.3	JORNADAS DE DIVULGACIÓN DE TRABAJOS DE INVESTIGACIÓN REALIZADOS POR ALUMNOS DE INGENIERÍA DE GRADO Y DE MÁSTER	63
5.3.1	Evaluación de técnicas de Deep Learning para la detección de anomalías en máquinas rotativas. Trabajo de Fin de Grado. Autora: D.ª Carlota López Argote	63
5.3.2	Aplicación de técnicas de Machine Learning al análisis de arranques de turbinas de gas de generación eléctrica. Trabajo de Fin de Grado. Autor: D. Daniel Vaquero Serrano	69
5.3.3	Aplicación de técnicas de Inteligencia Artificial al diagnóstico y mantenimiento de centrales eléctricas. Trabajo de Fin de Máster. Autor: D. Fernando del Pino Osborne	73
5.3.4	Caracterización del comportamiento de bombas de agua de circulación mediante técnicas de Machine Learning. Trabajo de Fin de Máster. Autora: D.ª Marta Casero Martín	79
5.3.5	Redes neuronales adversarias en el mundo IIoT. Uso de sus resultados en la estimación de ciclo de vida. Trabajo de Fin de Máster. Autor: D. Javier Álvarez Martínez	83
5.3.6	Aplicación de técnicas de Machine Learning al diagnóstico de la combustión de una turbina de gas. Trabajo de Fin de Máster. Autora: D.ª María del Carmen Rubiales Mena	89
5.3.7	Aplicación de técnicas de Machine Learning para el diagnóstico del comportamiento de bombas de agua de circulación de una central de generación eléctrica. Trabajo de Fin de Grado. Autor: D.ª Inés Rodríguez Aguilar	90
5.4	PUBLICACIONES CIENTÍFICAS	93
6	EVENTOS DE FORMACIÓN Y CAPACITACIÓN	97
6.1	WEBINARS SOBRE APLICACIONES DE LA IA	97
6.2	DATATHON	100
6.3	JORNADAS TÉCNICAS	103
6.4	CURSOS DE FORMACIÓN	105
7	VALOR DE LAS APORTACIONES DE LA CÁTEDRA	107

1

CREACIÓN DE LA CÁTEDRA DE APLICACIONES
DE LA INTELIGENCIA ARTIFICIAL AL
MANTENIMIENTO BASADO EN DATOS

ENDESA y la Universidad Pontificia Comillas, a través de su Instituto de Investigación Tecnológica (IIT) perteneciente a la Escuela Técnica Superior de Ingeniería ICAI, han estado colaborando y desarrollando proyectos de investigación desde hace más de 20 años. Fruto de esta colaboración, en el año 2018 se inició una nueva línea de investigación centrada en la aplicación de técnicas de Inteligencia Artificial al mantenimiento basado en datos de activos de generación, cuyo desarrollo ha impactado notablemente en el equipo y en la metodología de mantenimiento de ENDESA. Han sido varias las actividades que se han desarrollado de manera puntual en el transcurso de esa colaboración tanto de carácter formativo como proyectos de aplicación práctica. Los buenos resultados y sinergias entre ambas entidades motivaron la creación de un marco más flexible y estable de colaboración a medio plazo a través de la Cátedra de Aplicaciones de la Inteligencia Artificial al Mantenimiento Basado en Datos.

El acto de presentación de la cátedra, que sirvió también para oficializar la firma, tuvo lugar a finales de 2022 y contó con la intervención por parte de Comillas del Vicerrector de Investigación y Profesorado, D. Mariano Ventosa; el director de Comillas ICAI, D. Antonio Muñoz, y el director de la cátedra, D. Miguel Ángel Sanz. Por parte de ENDESA intervinieron el director general de Power Gen Iberia de Endesa, D. Rafael González; el responsable de Tecnología y Mantenimiento Mecánico y Sistemas, D. Tomás Álvarez, y el director de Operación y Mantenimiento de las Centrales de Gas, D. José Ribelles. La presentación contó además con la conferencia "Introduction to AI for the Electric Power Industry and use cases", impartida por Bobby Noble, program manager de EPRI.

Tras la creación, la Cátedra comenzó sus actividades en Enero de 2023.



Figura 1. Acto de constitución de la Cátedra

Esta memoria recoge en los siguientes apartados los principios en los que se basa la Cátedra y las actividades fundamentales desarrolladas desde su inicio. Éstas también se pueden consultar en su [página web](#).

2

OBJETIVOS
Y ALCANCE DE LA CÁTEDRA

La Cátedra de Aplicaciones de la Inteligencia Artificial (IA) al Mantenimiento Basado en Datos es una colaboración entre Endesa y la Universidad Pontificia Comillas con la misión de contribuir a que ENDESA en particular y el sector energético en general aprovechen las oportunidades que ofrece la Inteligencia Artificial mediante la generación de conocimiento y su difusión hacia la sociedad.

La Cátedra tiene como principales objetivos investigar y divulgar las aplicaciones de la Inteligencia Artificial en el ámbito del Mantenimiento y la Gestión de los activos de generación, con el fin de facilitar la transición energética hacia un modelo sostenible a largo plazo. Para ello ha venido utilizando tecnologías avanzadas en el área de la Inteligencia Artificial (IA) y el aprendizaje automático que permiten optimizar los recursos disponibles, mejorar la fiabilidad de los equipos, reducir costes operativos y alinearse con los Objetivos de Desarrollo Sostenible (ODS). Dentro del alcance de la Cátedra se han venido realizando actividades de investigación aplicada en temas de interés, formación en temas alrededor de la temática de la Cátedra, así como actividades de divulgación del uso de las técnicas de IA.

Como resultado de lo anterior en los tres años de andadura de la Cátedra se ha creado algo asimilable a lo que se podría denominar un “ecosistema” donde conviven y se interrelacionan diferentes perfiles técnicos para poder desarrollar las actividades de la Cátedra tales como personal de planta tanto de operación como de mantenimiento, personal encargado de los sistemas de gestión de la información, personal de apoyo técnico externo a planta, investigadores y alumnos. Ese potencial humano ha facilitado la realización de una investigación aplicada y colaborativa sobre casos reales, el desarrollo de herramientas digitales de apoyo a la operación y al mantenimiento, así como facilitar la formación y la divulgación de resultados. En definitiva, este “ecosistema” ha creado una robusta comunidad de aprendizaje y está dando una visión diferente a la tradicional sobre la cultura digital del mantenimiento. La ilustración que sigue muestra de forma esquemática el ecosistema descrito de actividades, personas y objetivos que busca satisfacer e interrelacionar colaborativamente los soportes básicos de la Cátedra.

ECOSISTEMA CÁTEDRA DE APLICACIONES DE LA IA AL MANTENIMIENTO BASADO EN DATOS



Figura 2. Esquema de objetivos, personas y alcance de la Cátedra

3

CONTEXTO DE TRABAJO

Endesa, empresa líder en la generación, distribución y comercialización de energía eléctrica en el mercado español destina anualmente recursos humanos y económicos para afianzar el correcto funcionamiento de sus activos. En este contexto Endesa promueve la cátedra de Cátedra de Aplicaciones de la Inteligencia Artificial (IA) al Mantenimiento Basado en Datos.

El Mantenimiento Basado en Datos (MBD) es el modelo que sustenta la Cátedra, y se apoya en dos pilares fundamentales:



1. Cambio Cultural hacia un Enfoque Digital en el Mantenimiento:

Se ha promovido un cambio cultural que incorpora tecnologías avanzadas, como la IA, para anticipar fallos y optimizar las intervenciones de mantenimiento permitiendo mejorar la fiabilidad y reducir los costes de mantenimiento.



2. Digitalización de la Gestión del Mantenimiento:

La plataforma GMDigital (*Global Maintenance Digital*) de ENDESA ha permitido centralizar todos los datos y procesos de mantenimiento, facilitando la toma de decisiones con información precisa sobre la operación, gestión económica y control del mantenimiento de los equipos.

A partir de estos pilares se promueve la cultura y conocimiento necesarios que tiene como objetivo dar respuesta a la optimización del ciclo completo de la gestión de los activos de generación eléctrica en base a:



- Análisis descriptivo: Que responde a la pregunta ¿Qué paso?



- Análisis de diagnóstico: Que responde a la pregunta ¿Por qué pasó?



- Análisis predictivo. Que responde a la pregunta ¿Qué pasaría en el futuro?



- Análisis prescriptivo. Que responde a la pregunta ¿Qué debería hacer acerca de ello?

Para poder dar respuestas a estas preguntas se profundiza en el conocimiento de cada una de las áreas y tipos de mantenimiento, no solo prediciendo el fallo, sino también ejecutando las intervenciones correctoras necesarias mitigando que estos fallos ocurran. Este enfoque permite una gestión completa del ciclo de mantenimiento obteniendo una gestión más eficiente, proactiva y sostenible. Esto supone poner en el centro del mantenimiento al dato y a la historia de estos.

La Figura 3 muestra la evolución del proceso de mantenimiento basado en datos que ha llevado a determinar el núcleo de las actividades de la Cátedra.




Figura 3. Diagrama del proceso de mantenimiento basado en datos aplicados en la cátedra

4

TIPO DE ACTIVIDADES
REALIZADAS

De acuerdo a los principios fundacionales de la Cátedra, en el período de los tres años de andadura de la misma se han ido desarrollando una serie de actividades que han demostrado poner en valor el impacto positivo de esta colaboración en las siguientes líneas de trabajo:

**Desarrollo de actividades de investigación aplicada**

La Cátedra ha facilitado el proponer, analizar y desarrollar un conjunto de soluciones basados en el mantenimiento basado en datos y técnica del ámbito de la IA favoreciendo la colaboración, el conocimiento y el alineamiento de intereses de todos los partícipes.

**Publicaciones y Difusión**

Se han publicado varios artículos académicos en revistas de impacto y conferencias internacionales sobre alguno de los resultados obtenidos en la Cátedra.

**Eventos de Formación y Capacitación**

- Los eventos de formación han sido actividades recurrentes con repetición anual, con el objetivo de crear cultura dentro de la empresa y posicionar la Cátedra como un referente en el sector. Entre estos eventos caben destacar:
 - Datathon: Un evento anual que reúne a estudiantes y empleados de Endesa, promovido por el CEO de Endesa, con el objetivo de difundir el uso de IA en el sector energético.
 - Webinars: Se han organizado varios webinars por año alrededor de temas actuales de la IA con una media de 250 asistentes.
 - Jornadas Técnicas: Se han compartido experiencias sobre técnicas y aplicaciones de la IA en mantenimiento industrial con empresas como Navantia, Repsol, Grupo Antolín, CAF y Airbus para conocer con más amplitud sectorial el estado del arte de la aplicación de dichas técnicas.

**Desarrollo de Talento Académico**

La Cátedra ha propiciado que empleados de Endesa inicien sus doctorados, demostrando su impacto en el desarrollo académico interno y contribuyendo al fortalecimiento del conocimiento técnico dentro de la empresa.

Los siguientes apartados detallan las actividades enunciadas en esas líneas de trabajo llevadas a cabo.

5

ACTIVIDADES DE INVESTIGACIÓN APLICADA



Las actividades de investigación aplicada se han articulado alrededor de casos reales interesantes desde el punto de vista práctico en los que se ha estimado que las técnicas de Inteligencia Artificial tenían gran potencial de ayuda a su solución o mejora.

5.1 DIAGNÓSTICO DE COMBUSTIÓN EN TURBINAS DE GAS MEDIANTE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**5.1.1 Introducción**

En este trabajo se describe un método basado en la combinación de varias técnicas de aprendizaje automático que trabajan en conjunto con el objetivo de monitorizar continuamente la combustión de una turbina de gas perteneciente a un ciclo combinado, mediante la observación de las mediciones de temperatura de los gases de escape disponibles y las variables de las condiciones de operación. El objetivo de esta monitorización es la detección automática de anomalías lo antes posible en las cámaras de combustión y de los posibles fallos en los termopares de medición en la turbina de gas. Se estudiaron cuatro turbinas de gas, cada una equipada con veintidós termopares ubicados en la salida de los gases de escape de las distintas turbinas para medir la temperatura en cada cámara de combustión.

El método de detección de anomalías desarrollado se basa en un conjunto que combina modelos que caracterizan el comportamiento normal esperado sin anomalías, en particular, se han aplicado redes neuronales y análisis de componentes principales (PCA). Estos modelos se utilizan para comparar el rendimiento actual de la turbina de gas con el rendimiento pasado en períodos de referencia conocidos como condiciones normales de funcionamiento. Si el comportamiento observado es diferente al esperado, se analiza para encontrar la causa de esta anomalía que podría estar enfocada en un termopar específico o en algunas cámaras de combustión. Esto es muy útil para planificar el mantenimiento y para ahorrar tiempo al eliminar el problema observado. En este trabajo se describen los métodos desarrollados y casos reales de aplicación. Los resultados obtenidos han validado la estrategia propuesta.

5.1.2 Estado del arte

A lo largo de los años, los avances en la tecnología de sensores e IIoT facilitaron la evolución de las estrategias de mantenimiento y, como se puede observar en la Figura 4, cada estrategia de mantenimiento posterior trae beneficios adicionales. Asimismo, también conlleva costes y complejidad adicionales.

Debido a eso, es difícil saltar dos o tres pasos hacia adelante en la evolución. Si el sistema está atascado en un modo reactivo, es muy difícil realizar una transición exitosa directamente al mantenimiento predictivo. [1]




Figura 4: Evolución de las estrategias de mantenimiento [1]

Hoy en día, los métodos de mantenimiento predictivo se dividen principalmente en tres categorías: pronóstico basado en modelos, pronóstico basado en el conocimiento y pronóstico basado en datos. [2][3]

El enfoque basado en datos no solo puede minimizar los costes de mantenimiento, sino que también puede extender la vida útil del equipo [4]. La diferencia entre el mantenimiento preventivo y el basado en datos es que mientras el primero toma medidas de máquinas que funcionan en tiempo real y advierte al usuario si se nota un problema, el segundo se basa en las mejores prácticas y datos históricos.

Por lo tanto, el mantenimiento basado en datos identifica los problemas antes para que puedan resolverse antes. Por otro lado, el mantenimiento basado en datos limitará los tiempos de inactividad no planificados y aumentará la vida útil del equipo al calcular cuándo el equipo necesita mantenimiento [4]. Los mismos conceptos pueden extrapolarse al campo de la detección y diagnóstico de anomalías de turbinas de gas, foco de este trabajo.

Se han realizado varios estudios sobre enfoques de mantenimiento basados en datos para reducir los problemas de la cámara de combustión en las turbinas de gas. Algunos de estos estudios desarrollan modelos de clasificación para comprobar si la turbina funciona correctamente, si falla un termopar o si hay puntos calientes o fríos en la distribución de la temperatura de salida. Han demostrado reconocer de manera eficiente los patrones de anomalías de los problemas comunes de combustión. [6]

Otros análisis han utilizado modelos híbridos basados en datos y basados en la física para el análisis prescriptivo de turbinas de gas. Mediante el uso de algoritmos como máquinas de vectores de soporte o redes neuronales artificiales y el estudio del comportamiento físico de cada una de las partes de la turbina de gas (como el flujo de calor generado de la cámara de combustión o el caudal y la eficiencia isentrópica del compresor en función de sus condiciones de trabajo) se ha demostrado que se pueden identificar con precisión diferentes disfunciones del motor en función de su rendimiento.

Además, se han identificado las principales limitaciones a la hora de trabajar con turbinas de gas, que son la falta de datos de ingeniería, fallos desconocidos no considerados durante los entrenamientos del modelo de aprendizaje automático y cambios en la combustión de la turbina de gas, lo que lleva a ajustar el modelo. [11]

Los sistemas de sensores interconectados transmiten mediciones desde la máquina a la nube creando conjuntos de datos para los modelos en tiempo real. Los modelos de aprendizaje automático se utilizan en este tipo de aplicaciones para detectar patrones en grandes conjuntos de datos y luego alertar cuando algo no está bien.




Figura 5: Diagrama genérico de un modelo de decisión

Estos modelos se entrenan con datos históricos donde el sistema se comportaba como se supone que debe hacerlo y luego se prueban con nueva información, para ver si está actuando como se predice que debe hacerlo. Como parte del mantenimiento basado en datos, el monitoreo de condición permite pronosticar un fallo adicional en función de las condiciones de trabajo del equipo eléctrico. Como se muestra en la Figura 5, el monitoreo de condición tiene diferentes etapas, siendo la parte más importante “Procesamiento de señales”. [12]

Los diferentes análisis que se pueden utilizar tienen en común que comienzan con la recopilación y el análisis de datos de la máquina en tiempo real. Posteriormente, se analizarían eventos anteriores en los que el sistema falló inesperadamente y eventos pasados en los que todo funcionó correctamente. De este modo, es posible saber si los datos que se están recopilando en este momento pueden considerarse normales o, por el contrario, si están fuera de lo común y deben activar una alarma.

5.1.3 Combustión de la turbina de gas y métodos de detección de fallo

El funcionamiento de una turbina de gas se puede explicar brevemente de la siguiente manera. En las turbinas de gas, el aire entra por la entrada de la turbina. Luego, el compresor aumenta la presión del aire antes de ingresar a la cámara de combustión. Este aire comprimido se mezcla con el combustible y se enciende, creando un gas caliente que se expande. Por último, este gas caliente impulsa la turbina de potencia y genera energía mecánica. [13][14]

Las diferentes partes de la turbina se pueden ver en la Figura 6. En este trabajo, se estudiaron cuatro turbinas de gas. Cada una está equipada con veintidós termopares cuyos valores se utilizarán como entradas para el sistema de detección de anomalías propuesto.

Además, cada una de estas turbinas cuenta con seis cámaras de combustión por lo que los termopares analizarán los gases de escape de diferentes cámaras. También debe tenerse en cuenta que a medida que cambia la potencia producida por la turbina, el flujo de los gases de escape se mueve de manera diferente, girando su posición (ángulo de remolino). Por este motivo, hay que tener en cuenta la potencia a la que está trabajando la máquina para saber a qué cámara de combustión corresponde la medición de cada termopar en cada momento.




Figura 6: Partes generales de una turbina [13]

La detección de anomalías en la combustión de la turbina de gas ha sido diseñada para una supervisión automática sobre la presencia o no de anomalías. El método utilizado se basa en un conjunto capaz de hibridar varios métodos de aprendizaje automático. En concreto, los modelos a utilizar son el análisis de componentes principales para reducir la dimensión de la salida (originalmente hay veintinueve temperaturas) y las redes neuronales para predecir las temperaturas esperadas en las cámaras de combustión de una turbina de gas en función de las entradas procedentes de las variables de funcionamiento de la turbina de gas. Para estos métodos, se analiza primero cuáles son las variables de entrada que mejor predicen la temperatura esperada en los períodos de referencia.

Hay ejemplos anteriores de diagnóstico de turbinas de gas utilizando algoritmos de aprendizaje automático, como redes neuronales. Como estas turbinas son complejas y costosas de reparar, todo debe rastrearse y analizarse en poco tiempo. Estas redes utilizan el modelo de caja negra, por lo que no requieren conocimientos de la física del problema permitiendo una alta velocidad computacional y cálculos en tiempo real.

5.1.4 Ensemble de modelos de machine learning para la detección de anomalías

Los métodos de conjunto son algoritmos de aprendizaje que construyen un conjunto de predictores y luego predicen nuevos puntos de datos tomando un voto (ponderado) de sus predicciones. El método de conjunto original es el promedio bayesiano, pero los algoritmos más recientes incluyen codificación de salida de corrección de errores, embolsado y aumento de datos [18]. Por lo tanto, como el sistema que se va a describir utiliza tres métodos de análisis diferentes y luego sopesa los resultados para llegar a una solución, se considera un método de aprendizaje automático conjunto.

Para llevar a cabo el análisis de la combustión de una turbina de gas, se ha decidido utilizar tres métodos de análisis diferentes: Análisis de componentes principales, la comparación entre la medición de cada termopar en cada observación con la media de todos los termopares en esa observación y una red neuronal.

Como se explicó anteriormente más atrás las observaciones estudiadas se han dividido por rangos de potencia producidos por la turbina, cada rango tiene aproximadamente cinco megavatios, para saber a qué cámara de combustión corresponde la medición de cada termopar. Tras realizar estos análisis, se estudian conjuntamente los resultados de cada uno de ellos para determinar el estado de los veintinueve termopares y de las seis cámaras de combustión y, en su conjunto, de la turbina de gas.

Además, de los tres análisis realizados, dos de ellos necesitan tener un periodo de referencia para entrenarlos. Los datos entre revisiones de la turbina de gas se han elegido para establecer los periodos de referencia, pero hay que tener en cuenta que pueden ser de diferentes tipos y que el tipo de revisión hace que el comportamiento al arrancar la turbina sea diferente.

Hay tres tipos diferentes de revisión, revisión mayor, revisión de componentes calientes y revisión de las cámaras de combustión. Al utilizar diferentes periodos de referencia, los resultados que se obtuvieron en los modelos fueron diferentes. Los resultados son más precisos cuando se utiliza como periodo de referencia la última revisión del mismo tipo que la última realizada que se considera exitosa.

Dado que el comportamiento de los gases de escape de la turbina cambia en función del último tipo de revisión realizada, se ha decidido que el plazo a utilizar como referencia debe ser de un año desde la última revisión considerada válida (es decir, que no haya dado problemas en ningún componente al arrancar la turbina) que sea del mismo tipo que la que se ha realizado en la turbina más recientemente. Por lo tanto, los datos utilizados como referencia serán todas las observaciones dentro de ese intervalo de un año que se encuentran dentro del intervalo de potencia que se está analizando.

Como la información a analizar se descarga en tiempo real, se ha decidido estudiar en cada análisis la última semana de muestras disponibles, siendo estas las últimas mil ocho observaciones desde la más reciente realizada que se encuentran dentro del rango de potencia que se está analizando debido a que las observaciones se toman con un intervalo de diez minutos entre sí. En resumen, este análisis pretende detectar fallos en las turbinas de forma eficiente y sencilla y diferenciar lo que los está produciendo, para solucionarlos cuando están empezando a suceder y pueden solucionarse fácilmente y no cuando ya son un problema grave y costoso. Esto se ha obtenido mediante la combinación de varios métodos de análisis.

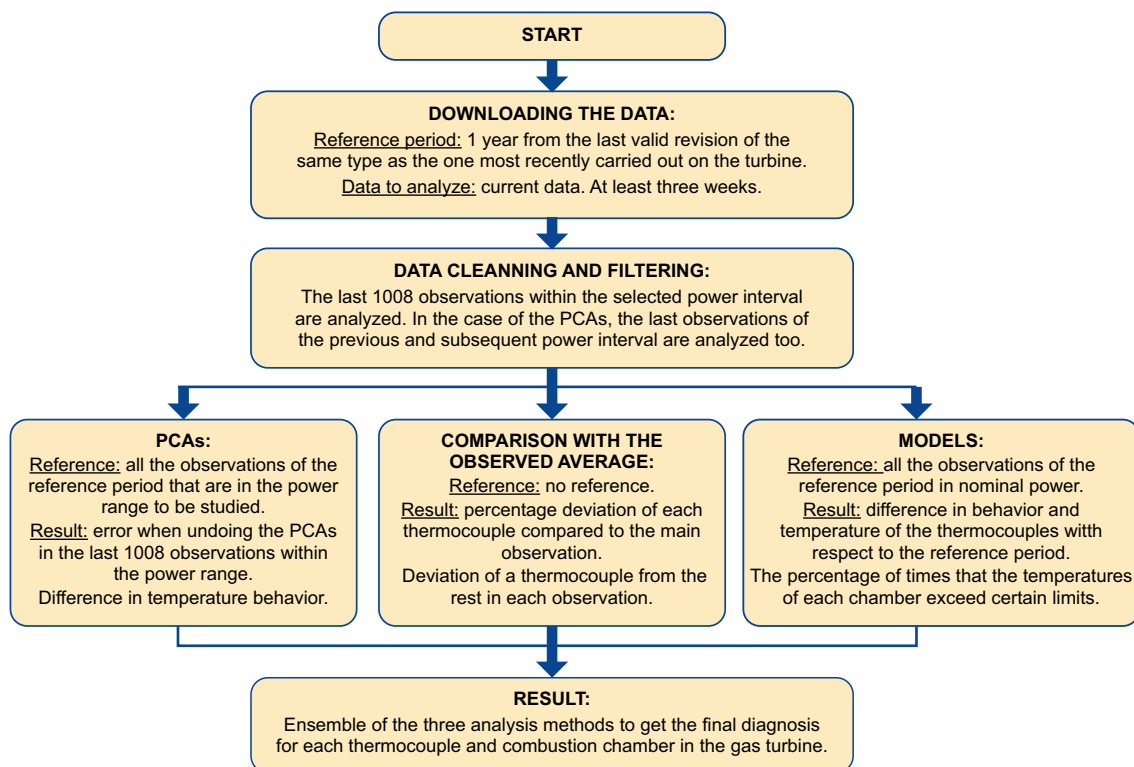


Figura 7: Esquema del proceso completo

En los siguientes apartados se detallará el funcionamiento de cada uno de los tres análisis: sus entradas, sus salidas y su interpretación. Posteriormente, se ilustrará la eficacia del sistema con un caso de funcionamiento normal y dos casos en los que el sistema ha detectado fallos en las turbinas, que luego se han verificado como realmente ocurridos.

En la Figura 7, se muestra un resumen del proceso. En primer lugar, la información se recupera en tiempo real y se limpia y filtra. De este modo, la información que se analiza corresponde a las turbinas que trabajan a potencia nominal en estado estacionario. El rango de potencia que se estudia es de 1 MW a 82 MW, siendo el estado estacionario entre 50 MW y 69 MW. Luego, los tres métodos analizan esta información al mismo tiempo, teniendo cada uno de ellos un resultado e interpretación diferente. Finalmente, el resultado se combina para determinar cómo se comporta la turbina, lo que convierte a este sistema en un método de aprendizaje automático conjunto.

Los tres métodos y sus usos son:

- **Análisis de componentes principales:** Analizar si existe un patrón de correlación diferente entre las temperaturas actuales y las temperaturas en un período de referencia.
- **Comparación entre la media de la observación y cada termopar:** Estudiando la desviación de cada termopar del resto en cada observación.
- **Modelos de comportamiento normal:** Analizando cuánto tiempo en el período los errores obtenidos de las cámaras de combustión estuvieron fuera de los umbrales.

5.1.4.1 Análisis de componentes principales

El primer análisis que se tuvo en cuenta fue el Análisis de Componentes Principales (PCA). PCA utiliza una transformación de espacio vectorial para reducir la dimensionalidad de grandes conjuntos de datos. Usando la proyección matemática, el conjunto de datos original, que puede haber involucrado muchas variables, a menudo se puede interpretar en solo unas pocas variables (los componentes principales). Por lo tanto, a menudo ocurre que un examen del conjunto de datos de dimensiones reducidas permitirá al usuario detectar tendencias, patrones y valores atípicos en los datos, mucho más fácilmente de lo que hubiera sido posible sin realizar el análisis de componentes principales. [16]




Figura 8: Varianza acumulada original descrita por cada una de las componentes principales

En primer lugar, se debe decidir cuántos componentes principales se van a utilizar. Para hacerlo, se debe examinar qué parte de la varianza original se explica por cada componente principal [17]. En la Figura 8 se puede ver un ejemplo de varianza acumulativa explicada de las variables originales, que en este caso son las temperaturas de los gases de escape de las cámaras de combustión, por cuántos componentes principales. En el caso de la Figura 9, cinco componentes principales explicarán más del noventa por ciento de la varianza de las variables originales para todos los rangos de potencia representados.

Por lo tanto, el número de Componentes Principales a utilizar depende de la variación de los datos iniciales que se quieran explicar, sabiendo que cuanto más se explique, mejor representarán las nuevas variables el comportamiento de las originales, pero se utilizarán más Componentes Principales.




Figura 9: Funcionamiento simplificado de las PCAs

Después de analizar cuántos componentes principales se necesitan, se debe crear una matriz de rotación base para convertir las variables originales en los componentes principales, que se basará en la proyección de las variables originales en la nueva base. En el estudio de caso, la matriz de rotación se creó utilizando las temperaturas de los gases de escape del período de referencia, dentro del rango de potencia estudiado.

Después de crear esta matriz, se utilizó para convertir las variables originales en componentes principales y luego se deshizo el cambio para obtener las temperaturas nuevamente. Posteriormente, se compararon las temperaturas reales del periodo de referencia con las temperaturas obtenidas tras hacer y deshacer los Componentes Principales y el error en el periodo de referencia al aplicar los Componentes Principales. Este error de reconstrucción se calcula como la media de las temperaturas reales de todas las observaciones menos la temperatura estimada para todas las observaciones al cuadrado para cada termopar.

A continuación, se utiliza la matriz de rotación del período de referencia para transformar las temperaturas observadas en el nuevo período para transformarlas en componentes principales. Después de aplicar el cambio y obtener los Componentes Principales, se deshace y el error se obtiene de la misma manera

que en el período de referencia. La matriz de rotación que se calculó en el período de referencia se utiliza nuevamente para el nuevo período ya que, si las temperaturas se comportan de la misma manera que en este período, el resultado esperado de los Componentes Principales es similar en ambos períodos.

Una vez obtenidos los errores de los dos periodos, se restan, para ver cuánto ha aumentado el error en el nuevo periodo de datos respecto al periodo de referencia. Estos errores se utilizarán después de todo el análisis para determinar el comportamiento de cada termopar. Cuanto mayor es esta diferencia, más difiere el comportamiento actual de los gases de escape del comportamiento que tenían en el período de referencia, que se consideró el comportamiento correcto. Los errores en las cámaras de combustión se obtienen como el error medio de los termopares que corresponden a cada cámara de combustión en el rango de potencia estudiado.

5.1.4.2 One versus all

Este método de análisis no necesita un período de referencia ya que compara lo que mide cada termopar en cada observación con el promedio de las mediciones en esa observación de todos los termopares. Posteriormente, se calcula el número de veces que cada termopar ha tenido una temperatura mayor que la media de la observación más 2,5 % o menor que la media de la observación menos 2,5 %.




Figura 10: Temperaturas de las últimas cincuenta observaciones en un caso normal

Dado que la turbina está trabajando a un nivel de potencia estable cuando trabaja continuamente y dado que todas las cámaras de combustión están construidas de la misma manera y funcionan de la misma manera, se espera que la temperatura de los gases de escape sea similar en todos los termopares. De esta forma, si uno de los termopares tiene una temperatura mucho más alta o baja que el resto, se puede detectar que la distribución de temperatura no es homogénea y que por lo tanto hay algo no normal en la cámara de combustión asociado a ese termopar. Por lo tanto, esta información de análisis se puede utilizar como una medida de uniformidad.

Para ilustrar esto, se muestran dos casos operativos diferentes en la Figura 10 y la Figura 11. En esos gráficos, se muestran las temperaturas de los termopares para las últimas cincuenta observaciones. La observación más reciente se muestra en rojo y el resto se muestra en gris, siendo la más clara la más antigua.

En la Figura 10 se puede ver que todos los termopares están trabajando a una temperatura similar, por lo que el funcionamiento de las cámaras de combustión se considera correcto. En la Figura 11 se observa que la temperatura no es similar entre los diferentes sensores. En este caso, se estaba produciendo una entrada de aire en una de las cámaras de combustión, lo que provocó que los termopares de esa cámara tuvieran una temperatura más baja. El resto de las cámaras tuvieron que elevar su temperatura para seguir produciendo la misma potencia y compensar el error. Se puede observar que la distribución homogénea de las temperaturas ya no se mantiene porque algunos de los sensores tienen una temperatura más baja y otros tienen una más alta. Este análisis detectaría este comportamiento como anormal.




Figura 11: Temperaturas de las últimas cincuenta observaciones en un caso defectuoso

El error obtenido entre los sensores y la media de la observación se utilizará después de los tres análisis para caracterizar el comportamiento de los termopares.

5.1.4.3 Modelos de comportamiento normal

Las variables utilizadas como entradas para estos modelos son la potencia que está produciendo la turbina, el caudal másico de aire de entrada del compresor, el flujo de combustible, la temperatura de descarga del compresor, la humedad en el área, la temperatura de entrada del compresor y el tiempo transcurrido desde la última acción de mantenimiento. Un conjunto de entrenamiento se crea utilizando las mediciones tomadas después de una revisión que se consideró exitosa.

Es importante diferenciar los tipos de revisiones que se realizaron, ya que las variables de entrada se comportan de manera diferente después de cada una. Una vez construido el modelo de comportamiento normal esperado, se utiliza el conjunto de pruebas para realizar la predicción de las temperaturas medias de las cámaras de combustión en el periodo analizado. Comparando este pronóstico con las temperaturas promedio reales observadas, se pueden detectar anomalías con respecto al comportamiento normal esperado. Para evaluar el rendimiento de este modelo, las métricas que se tienen en cuenta son la precisión del modelo, el error medio absoluto (MAE) y el error cuadrático medio (RMSE).

Estos modelos de comportamiento normal tienen como objetivo representar la relación entre la temperatura media observada en cada cámara de combustión y las condiciones de operación de la planta. El algoritmo de estos modelos se implementa en *keras* y *tensorflow*, con varios niveles de tipo "dense". Se utiliza el período de referencia previamente definido, cuyas observaciones están dentro del rango de potencia estudiado. Además, los termopares se agrupan por cámaras de combustión para poder observar su comportamiento en su conjunto.

Posteriormente, se calcula el número de veces que el error del modelo sometido a ensayo está fuera del rango que forma el error medio de la cámara de combustión sometida a entrenamiento más o menos la desviación estándar de este error. Para estos modelos, las entradas son diferentes variables de funcionamiento como la humedad ambiental en la zona donde se encuentran las turbinas, los flujos de aire y combustible utilizados, las vibraciones en diferentes componentes de la máquina o las revoluciones a las que trabaja la turbina. De esta forma, se puede predecir la temperatura que seguramente tendrán las cámaras de combustión y, comparándolas con las temperaturas reales obtenidas, se puede ver lo diferente que es el comportamiento actual de la turbina de lo que debería ser.

Realizando los modelos con los diferentes tipos de revisiones estudiadas, se observó que las temperaturas medias de las cámaras de combustión y su evolución en el tiempo difieren en función del tipo de revisión realizada justo antes de obtener estos datos. Con ello, se comprobó que se debe tener en cuenta la última revisión realizada en la turbina para poder tener un periodo de referencia también tras una revisión del mismo tipo, ya que el comportamiento de las cámaras de combustión cambiaba de una a otra.

Como los fallos pasados de las turbinas que se catalogaron se deben a entradas de aire en las cámaras de combustión u otros problemas que hacen que baje la temperatura media de las cámaras de combustión, estos modelos tienen en cuenta para el resultado final las cámaras de combustión en las que la temperatura real es inferior a la esperada. En estos casos, en los que algunas cámaras de combustión disminuyen sus temperaturas, otras aumentan la suya, pero esto es normal ya que compensan el error de tener la misma temperatura media en la turbina en general que tendría la turbina si no hubiera fallo.

5.1.5 Resultados

5.1.5.1 Detección del comportamiento normal de las cámaras de combustión

En este primer ejemplo, se estudia el comportamiento de una turbina que trabaja en el rango entre 53 y 57 MW. Se analizan las temperaturas medias de cada termopar en ese rango de potencia, agrupándolas en intervalos de 0,5 MW. En la Figura 12 se puede observar que la diferencia máxima de temperaturas medias entre termopares es de 30°C en todo el rango de potencia. También se puede observar que las temperaturas medias de los termopares dependen del intervalo que se representa, siendo estas temperaturas más altas si el intervalo de potencia es mayor.

Las temperaturas de los termopares en las últimas cincuenta observaciones se trazan en la Figura 13. Si la turbina funciona correctamente, este gráfico debería mostrar una circunferencia, en la que las temperaturas de cada termopar para cada observación sean similares al resto.




Figura 12: Distribución de las temperaturas de salida en función de la potencia producida

En la Figura 13 la observación más reciente se muestra en rojo. El resto de las observaciones se muestran en gris, siendo el color más claro cuanto más en el pasado es la observación.

Outlet temperatures, last 50 observations: 53 - 57 MW




Figura 13: Distribución de las temperaturas de las últimas cincuenta observaciones por termopar

Luego se realiza el análisis de componentes principales para las observaciones actuales. El resultado de este análisis se muestra en tres gráficos que se representan conjuntamente. Estos tres gráficos representan el resultado del comportamiento de los termopares y las cámaras de combustión en el rango de potencia analizado, en el rango de potencia anterior y en el siguiente rango de potencia.




Figura 14: Resultados del análisis de componentes principales

En la Figura 14 se puede ver que en cada gráfico de esta sección los termopares están representados con la cámara de combustión a la que pertenecen, y que esta correspondencia cambia dependiendo de la potencia que produce la turbina. También se puede ver que en este ejemplo el error obtenido con el PCA fue lo suficientemente pequeño como para considerar el comportamiento de los termopares y las seis cámaras como correcto.

El siguiente análisis realizado a las observaciones es comparar la temperatura medida por cada termopar en cada observación con la media de las temperaturas para esa observación. Si la medición del termopar está entre el rango $[media - desviación, media + desviación]$ el comportamiento del termopar se considera normal.

Como se muestra en la Figura 15, el resultado de este análisis se forma como una combinación de un gráfico de radar y una tabla. En el gráfico de radar, la última observación se muestra en rojo y los límites para considerar que las mediciones son normales se muestran en gris. En la tabla se enumera cada termopar, con la cámara de combustión a la que pertenecen en ese momento y el número de veces que las observaciones de cada termopar estuvieron fuera de los límites, dividiendo esta medida en el número de veces que fue superior al límite superior e inferior al límite inferior. El número de veces que la medición estuvo fuera del límite se representa como el porcentaje de veces del número total de observaciones entre 53 y 57 MW.




Figura 15: Comparación entre la media de la observación y la media de cada termopar

En este ejemplo, se considera que algunos termopares están fuera de los límites y se representan en naranja y rojo. El sistema determinará si esos termopares están fallando al final, cuando tenga en cuenta los resultados de todos los análisis realizados.

Finalmente, en la Figura 16 se muestra el resultado del modelo de operación de condición normal. La forma de representarlos es similar a la Figura 15, con un gráfico de radar que representa el error medio por cámara de combustión y el límite superior e inferior de ese error.

Como los casos de errores utilizados para entrenar los modelos fueron casos en los que la temperatura de las cámaras de combustión disminuía, para el resultado final solo se considera el número de veces en porcentaje que el error obtenido de los modelos supera el límite inferior. Por lo tanto, el número de veces que se supera el límite superior se representa sin una gama de colores.




Figura 16: Resultados de la red neuronal

En la Figura 16 se puede ver que para este ejemplo todas las cámaras de combustión se comportaban como se esperaba entre 53 y 57 MW y, por lo tanto, se clasifican como verdes.

5.1.5.2 Fallo en dos cámaras de combustión por la entrada de aire




Figura 17: Distribución de las temperaturas de los gases de escapes en función de la potencia producida

Para este ejemplo, hubo un fallo en dos de las cámaras de combustión debido a una entrada de aire. En la Figura 17 se puede ver que la diferencia entre la máxima y la mínima en las temperaturas medias es ahora de 80°C. También se puede observar que para el decimoséptimo termopar hay una disminución de la temperatura media en todos los rangos de potencia que se analizan.

Además, ya no se sigue la distribución de temperatura que se siguió en el caso normal. El rango de potencia más bajo analizado no corresponde a las temperaturas medias más bajas. Estas temperaturas ya no siguen un orden claro y los diferentes intervalos de potencia se mezclan, sin mantener una posición fija.

Como el rango de potencia estudiado en este ejemplo es mayor que el estudiado más atrás las temperaturas representadas en la Figura 18 también son más altas. A partir de este gráfico se puede observar que la distribución de la temperatura ya no se asemeja a una circunferencia, ya que hay algunos termopares, como el decimoséptimo y el tercero, en los que la temperatura disminuyó y otros, como el vigésimo primero o el segundo, en los que ha aumentado.

Outlet temperatures, last 50 observations: 58 - 63 MW




Figura 18: Distribución de las temperaturas de las últimas cincuenta observaciones

En la Figura 19 se muestra el resultado del análisis de componentes principales. En este caso, varios termopares tienen un comportamiento errático rompiendo la estructura de correlación entre la medida de diferentes termopares, lo que conduce a un error mayor también en las cámaras de combustión.




Figura 19: Resultados del análisis de PCAs

Estos termopares marcados en naranja y en rojo corresponden a las cámaras donde se producía la entrada de aire pero también a las posiciones opuestas en la turbina de gas. Cuando hay una disminución de temperatura en una de las cámaras, el resto de ellas sufren un aumento de temperatura para compensar y poder producir la misma potencia. Por lo tanto, algunos termopares tienen temperaturas más altas de lo esperado y se clasifican como sensores defectuosos.

En la comparación de cada termopar con la media de la observación se puede ver que hay varios termopares que están fuera de rango. La desviación más alta es para el decimotercero termopar que tenía una temperatura inferior al límite en el 42,58 % de las observaciones, como se muestra en la Figura 20.




Figura 20: Comparación entre la media de la observación y la temperatura medida por cada termopar

El resultado de la red neuronal, representado en la Figura 21, muestra que las temperaturas de la tercera y cuarta cámara de combustión fueron más bajas de lo esperado, y son las únicas marcadas como fallidas.




Figura 21: Resultados de la red neuronal

5.1.5.3 Fallo en una cámara de combustión derivado de una anomalía en uno de los inyectores

Evolution of the outlet temperatures group by 0,5 MW intervals
 Range: 58 - 63 MW




Figura 22: Distribución de la temperatura de los gases de escape en función de la potencia producida

En este último ejemplo, hubo un fallo en un inyector en la tercera cámara de combustión y, por lo tanto, la temperatura de esta cámara fue más baja de lo esperado. En la Figura 22 se puede ver que las temperaturas de los termopares 17 y 6 fue más baja de lo esperado.

Outlet temperatures, last 50 observations: 58 - 63 MW




Figura 23: Distribución de las temperaturas de las últimas cincuenta observaciones por termopar

Además, la diferencia entre la temperatura media máxima y la temperatura media inferior es de 65°C. La distribución de las temperaturas, como se muestra en la Figura 23, no encaja con una circunferencia. Hay algunos termopares para los que la temperatura es más baja que para el resto.

Como resultado de las PCA, se puede ver en la Figura 24 que varios termopares no se comportan como se esperaba. Además, entre 58 y 63 MW, dos cámaras de combustión también se consideran fuera de los límites. En los tres rangos de potencia analizados, los termopares que corresponden a la tercera cámara de combustión tienen un error alto, lo cual era de esperar teniendo en cuenta que el inyector defectuoso estaba en la tercera cámara.




Figura 24: Resultado del análisis de las PCAs

En el análisis que compara la temperatura medida por cada termopar con la media de la observación, también se puede ver que varios termopares están fuera de límites. Como se muestra en la Figura 25, los termopares que corresponden a la tercera y cuarta cámara de combustión tienen temperaturas más bajas de lo esperado y los termopares de la quinta y sexta cámaras de combustión tienen temperaturas más altas de lo esperado. Este aumento en las temperaturas se debe a que la turbina intenta producir el mismo rango de potencia, incluso si dos cámaras están fallando. Si solo se estudiara la temperatura media de la cámara de combustión o la potencia producida por la turbina de gas, este desequilibrio de temperatura podría pasar desapercibido.




Figura 25: Comparación entre la media de la observación y la medida de cada termopar

Finalmente, los resultados de la red neuronal, que se muestran en la Figura 26, muestran errores negativos significativos de la tercera, cuarta y quinta cámara de combustión. También se puede notar que la representación de estos errores en el gráfico del radar ya no representa una circunferencia o algo cercano a ella, ya que exceden el límite inferior en diferentes medidas, dependiendo de cuán diferentes sean las temperaturas predichas de las temperaturas reales que ocurren en la turbina de gas.




Figura 26: Resultados de la red neuronal

5.1.6 Ensemble y resultado final

Después de haber realizado estos análisis por separado a las temperaturas del período a estudiar, se obtiene una medición de error para cada cámara de combustión y para cada termopar. Como en los tres análisis se utilizan los mismos periodos de referencia y se analizan los mismos datos nuevos, para obtener el error total de cada sensor y de cada cámara se realiza la media de los errores obtenidos individualmente para el resultado final.

Por lo tanto, el siguiente paso en el análisis es hacer el conjunto de los diferentes análisis realizados. La combinación de los resultados de los diferentes modelos compensa los errores que puedan haber tenido y da un resultado más robusto. Generalmente se distinguen dos familias de métodos de conjunto: [18][19][20][21]

- **Métodos de promediación:** El principio impulsor es construir varios estimadores de forma independiente y luego promediar sus predicciones. En promedio, el estimador combinado suele ser mejor que cualquiera de los estimadores de base única porque su varianza se reduce.
- **Métodos de Boosting:** Los estimadores base se construyen secuencialmente y se intenta reducir el sesgo del estimador combinado. La motivación es combinar varios modelos débiles para producir un conjunto poderoso.

El resultado final se indica mediante un código de tres colores (verde, naranja y rojo, siendo el rojo el peor) de qué tan desviado está el termopar o cámara de combustión de su funcionamiento esperado. El objetivo principal del trabajo era diferenciar si los errores que se detectan se deben a sensores que no funcionan correctamente o a la propia cámara de combustión. Si el fallo es de una cámara de combustión, estos análisis devolverían fallos tanto en la cámara de combustión como en los sensores que la componen, mientras que si el fallo es un termopar defectuoso, solo este termopar se marcaría como erróneo en el gráfico final.




Figura 27: Resultados finales en situación de comportamiento normal

El resultado final se muestra al usuario a través de un gráfico simplificado que resume los análisis realizados. Al hacer esto, se observa claramente dónde hay un fallo, si es que la hay. También se han desarrollado gráficos auxiliares que permiten ver la evolución de los termopares y cámaras de combustión para los tres análisis y el resultado final a lo largo del tiempo para detectar desviaciones desde el principio.

Este gráfico simplificado se puede ver en la Figura 25 para una situación en la que el comportamiento de la turbina de gas es normal. Dependiendo del rango de potencia que se analice, los termopares se mostrarán asociados a la cámara de combustión que representan en ese rango. Por lo tanto, los termopares no tienen una posición fija en el gráfico, sino que cambian de grupo según sea necesario. Esto se puede ver en los siguientes ejemplos. En el caso mostrado en la Figura 27 se consideraría que toda la turbina funciona correctamente. Este resultado sería el resumen del ejemplo analizado más atrás.

La Figura 28 muestra otro caso de fallo. En este ejemplo, el fallo se debió a que el aire ingresó a las cámaras de combustión tres y cuatro, lo que afectó su temperatura y la de la cámara en general. En este caso, las cámaras de combustión tres y cuatro y los termopares en esa área se marcaron como defectuosos, lo cual es correcto. Los otros dos termopares marcados como erróneos en la cámara cinco midieron temperaturas superiores a las esperadas ya que en este caso la temperatura media de la turbina también se mantuvo constante en general, para poder seguir produciendo la misma potencia. En este caso, este es el resultado del análisis explicado más atrás.




Figura 28: Resultado final en situación de fallo

También se puede observar que, dado que este ejemplo analiza un rango de potencia diferente a los otros dos explicados en esta sección, los termopares han cambiado su posición con respecto a las cámaras de combustión. Como se explicó anteriormente, en cada rango de potencia los termopares representan diferentes cámaras de combustión, por lo que el código desarrollado corrige automáticamente este cambio y los muestra siempre en su posición correcta. Al pasar de un rango de potencia al anterior o al siguiente, lo que se espera es que solo tres termopares cambien de una cámara de combustión a la siguiente, pero si se estudian rangos de potencia más separados, el cambio es más significativo.




Figura 29: Resultado final en situación de fallo

Otro ejemplo se puede ver en la Figura 29. Este caso muestra un ejemplo en el que una de las cámaras de combustión no funcionaba correctamente. En concreto, un problema en un inyector de la tercera cámara de combustión provocó que la temperatura en el mismo fuera inferior a la temperatura del resto de cámaras. Las mediciones de tres termopares se identificaron como anómalas. Los termopares de la tercera cámara de combustión muestran una condición anómala ya que la temperatura que estaban midiendo era considerablemente inferior a la esperada, por lo que el sistema indica que su comportamiento no es el esperado. Por otro lado, para mantener la temperatura media de la turbina, el resto de las cámaras de combustión tienen que elevar sus temperaturas. Este aumento de temperatura no es suficiente para indicar que todas las cámaras están fallando, pero es suficiente para decir que el termopar seis está fallando, ya que mide constantemente temperaturas más altas de lo esperado. Este gráfico se obtendría como resultado del análisis explicado más atrás.

5.1.7 Conclusiones

En esta investigación se ha propuesto un método basado en la combinación de varias técnicas de aprendizaje automático trabajando juntas en un “ensemble”, con el objetivo de vigilar de forma continua la combustión de una turbina de gas en un ciclo combinado mediante la observación de las medidas de temperatura de los gases de escape y las variables de las condiciones de operación disponibles. El objetivo de esta monitorización es la detección automática lo antes posible de anomalías en las cámaras de combustión, así como posibles fallos en los termopares de medida de la turbina de gas. Se estudiaron cuatro turbinas de gas, cada una de ellas equipada con veintidós termopares situados en la salida de los gases de escape para medir la temperatura en cada cámara de combustión. Estos sensores están distribuidos simétricamente en un círculo.

El método de detección de anomalías desarrollado se basa en un “ensemble” que combina modelos contruidos con distintas técnicas de aprendizaje automático que caracterizan el comportamiento normal esperado para unas condiciones de operación sin anomalías, pero también el análisis de las temperaturas

reales de la turbina de gas. En particular, se han aplicado redes neuronales y análisis de componentes principales (PCA).

Estos modelos se utilizan para comparar el comportamiento actual de la turbina de gas con el mismo en periodos de operación similares usados como referencia de condiciones normales de operación, en los que se observa una distribución homogénea de las temperaturas de los gases de escape y debe cumplirse una relación funcional entre estas temperaturas y variables de operación tales como la potencia de salida. Si el comportamiento observado es significativamente diferente de lo que el sistema diseñado espera, se realiza un análisis para encontrar la causa de esta anomalía que podría estar centrada en un termopar específico o en una o varias cámaras de combustión. La anomalía se asociará a un modo de fallo de cámara de combustión si se observan varios termopares de la misma cámara de combustión con comportamiento distinto del esperado. Esto es muy útil para planificar el mantenimiento y para ahorrar tiempo al eliminar el problema observado. Además del desarrollo del método, éste se ha aplicado a varios casos reales de aplicación. Los resultados obtenidos han validado la estrategia propuesta. Aunque otros modos de fallo pueden ocurrir, el método propuesto se ha centrado en identificar anomalías lo más pronto posible en las cámaras de combustión de las turbinas de gas. La Figura 30 muestra un ejemplo de cómo el usuario puede ver la situación de la cámara de combustión cuando no se detecta anomalía en la proximidad de los termopares.



Figura 30. Imagen pantalla de monitorización de la cámara de combustión y de los termopares asociados

En el fallo mostrado en la Figura 29, que es el más reciente, se ha podido comprobar cómo en un período de dos o tres semanas el sistema pasó de dar indicios de un fallo menor a otra más importante, a medida que aumentaba la diferencia de temperaturas. En otras palabras, el sistema pudo detectar el error tan pronto como ocurrió y también seguir su evolución a lo largo del tiempo. Además de observar que los sistemas son sensibles a la última revisión realizada, se ha visto que es más fácil caracterizar el comportamiento de las cámaras de combustión si los datos se dividen en intervalos de potencia, ya que es más fácil saber qué termopares representan qué cámara de combustión. Por lo tanto, se concluye que se ha logrado el objetivo del artículo y que hay evidencia de ello.

5.1.8 Referencias

- [1] "Is there a best maintenance strategy? 5 maintenance strategies compared," Limble CMMS, 2021. [Online]. Available: <https://limblecmms.com/blog/maintenance-strategy/>
- [2] H. M. Hashemian, "State-of-the-art predictive maintenance techniques," IEEE Systems Journal, 2013. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/5659691>
- [3] L. Spendla, M. Kebisek, P. Tanuska, and L. Hrcka, "Concept of predictive maintenance of production systems in accordance with industry 4.0," IEEE Systems Journal, 2017. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7880343>
- [4] W. Zhang, D. Yang, and H. Wang, "Data-driven methods for predictive maintenance of industrial equipment: A survey," IEEE Systems Journal, 2019. [Online]. Available: <https://ieeexplore.ieee.org/document/8707108>
- [5] J. E. G. T. Power, "Gas turbine combustion optimization using neural network model and wavelet analysis," DOI, 2022. [Online]. Available: <https://asmedigitalcollection.asme.org/gasturbinespower/article-abstract/144/8/081003/1140779/Gas-Turbine-Combustion-Optimization-Using-Neural?redirectedFrom=fulltext>
- [6] C. Allegorico and V. Mantini, "A data-driven approach for on-line gas turbine combustion monitoring using classification models," PHM Society European Conference, 2014. [Online]. Available: <https://papers.phmsociety.org/index.php/phme/article/view/1461>
- [7] M. M. Montaña and M. Á. S. Bobi, "Anomaly detection indicators of a wind turbine gearbox based on feature extraction from its vibration performance," PHM Society European Conference, 2018. [Online]. Available: <https://papers.phmsociety.org/index.php/phme/article/view/61>
- [8] Z.-t. Wang, N.-b. Zhao, W.-y. Wang, R. Tang, and S.-y. Li, "Aon accurate and reliable anomaly detection for gas turbine combustors: A deep learning approach," arXiv, 2019. [Online]. Available: <https://arxiv.org/abs/1908.09238>
- [9] W. Yan and L. Yu, "A fault diagnosis approach for gas turbine exhaust gas temperature based on fuzzy c-means clustering and support vector machine," DOI, 2015. [Online]. Available: <http://dx.doi.org/10.1155/2015/240267>
- [10] X. Yang, Y. Zhang, W. Lv., and D. Wang, "Image recognition of wind turbine blade damage based on a deep learning model with transfer learning and an ensemble learning classifier," ScienceDirect, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S0960148120313707>
- [11] S. Belov, S. Nikolaev, and I. Uzhinsky, "Hybrid data-driven and physics-based modeling for gas turbine prescriptive analytics," MDPI, 2020. [Online]. Available: <https://www.mdpi.com/2504-186X/5/4/29#cite>
- [12] K. Kudelina, T. Vaimann, B. Asad, A. Rassölkin, A. Kallaste, and G. Demidova, "Trends and challenges in intelligent condition monitoring of electrical machines using machine learning," MDPI, 2021. [Online]. Available: <https://www.mdpi.com/2076-3417/11/6/2761>

- [13] S. turbines. "Cómo funciona una turbina de gas." (2021), [Online]. Available: https://www.solarturbines.com/es_MX/products/gas-turbines.html (visitado el 02/10/2022)
- [14] B. Zohuri. "Gas turbine working principles." (2015), [Online]. Available: https://www.researchgate.net/publication/300857212_Gas_Turbine_Working_Principles (visitado el 06/06/2022)
- [15] M. Irfan, N. Saad, D. Zhen, N. Haider, A. Glowacz, and A. AlShorman, "A review of artificial intelligence methods for condition monitoring and fault diagnosis of rolling element bearings for induction motor," Hindawi, 2020. [Online]. Available: <https://www.hindawi.com/journals/sv/2020/8843759/>
- [16] M. Richardson, "Principal component analysis," 2009. [Online]. Available: <http://aurora.troja.mff.cuni.cz/nemec/idl/09bonus/pca.pdf>
- [17] I. T. Jolliffe and J. Cadima, "Principal component analysis: A review and recent developments," 2016. [Online]. Available: <https://doi.org/10.1098/rsta.2015.0202>
- [18] T. G. Dietterich, "Ensemble methods in machine learning," 2000. [Online]. Available: https://doi.org/10.1007/3-540-45014-9_1
- [19] scikit learn. "Ensemble methods." (2022), [Online]. Available: <https://scikit-learn.org/stable/modules/ensemble.html> (visitado el 06/05/2022)
- [20] IArtificial.net. "Ensembles: Voting, bagging, boosting, stacking." (2019), [Online]. Available: <https://www.iartificial.net/ensembles-voting-bagging-boosting-stacking/> (visitado el 06/05/2022)
- [21] N. Batayev, "Gas turbine fault classification based on machine learning supervised techniques," 2018. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8634719/authors#authors>

5.2 GMTWIN: ANÁLISIS PREDICTIVO DE FALLOS EN EQUIPOS

Este proyecto impulsado por la Cátedra tiene como objetivo desarrollar un “framework” integral de mantenimiento predictivo y prescriptivo basado en datos, concebido para su integración directa en la plataforma digital de ENDESA, con el fin de potenciar sus capacidades operativas y de toma de decisiones. La Figura 31 ilustra cómo esta investigación se alinea e integra con otras aplicaciones digitales de la compañía, consolidando y dando continuidad al proceso de digitalización de la gestión del mantenimiento, una línea estratégica que ENDESA ya había iniciado antes del nacimiento de esta Cátedra.

En concreto, este “framework” pretende:

- Proporcionar una plataforma unificada de seguimiento del mantenimiento, incluyendo la predicción de fallos probables, el estado de salud de los activos, y recomendaciones de actuación.
- Generar un plan óptimo de mantenimiento futuro, considerando tanto el estado de los equipos como la disponibilidad de recursos y repuestos, en conexión con los sistemas de gestión de almacenes, gestión de pedidos y gestión del mantenimiento.

De esta manera, para lograr los objetivos anteriores, la investigación se articula en distintas fases. Esta memoria documenta la Fase 1, centrada en:

- La detección temprana de anomalías mediante modelos basados en datos.
- La evaluación cuantitativa de la eficacia de las acciones de mantenimiento realizadas.

Este primer bloque funcional representa la base diagnóstica del “framework” completo, que permitirá en fases posteriores construir las capacidades predictivas y prescriptivas necesarias para la planificación estratégica del mantenimiento.



Figura 31. Esquema que muestra la integración de GMTwin con distintos objetos y productos

5.2.1 Presentación y objetivos de la Fase 1

En el contexto de la transformación digital y el mantenimiento predictivo en entornos industriales, una de las principales limitaciones actuales es la carencia de métodos fiables que permitan evaluar de forma cuantitativa la efectividad de las acciones de mantenimiento. Por este motivo, esta Fase 1 de la investigación constituye el núcleo central de un novedoso método para evaluar la eficacia de las acciones de mantenimiento y su impacto en la salud de equipos industriales en general.

Los objetivos de la Fase 1 son los siguientes:

- Diseñar un método cuantitativo para identificar comportamientos anómalos en equipos industriales a partir de datos operativos.
- Diseñar un método para evaluar cuantitativamente el impacto de las acciones de mantenimiento sobre el estado de salud de los equipos, utilizando indicadores de riesgo.
- Validar el método en un caso de estudio real proporcionado por ENDESA.
- Establecer la base para su futura integración en la plataforma digital de la compañía.

5.2.2 Metodología

La metodología propuesta se fundamenta en el concepto de comportamiento normal esperado de un componente o sistema industrial, modelado mediante un Gemelo Digital. Este modelo permite comparar, en tiempo real, el comportamiento observado con el comportamiento teóricamente esperado bajo condiciones normales de operación (NOC en inglés). A partir de esta comparación, es posible identificar desviaciones significativas que actúan como síntomas tempranos de posibles modos de fallo. El análisis continuo de estas desviaciones ha dado lugar a la formulación de un nuevo indicador denominado “riesgo de aparición de un modo de fallo”, que cuantifica la probabilidad relativa de que un fallo se materialice. Este indicador tiene una doble utilidad: por un lado, permite anticipar y recomendar acciones de mantenimiento cuando el riesgo supera ciertos umbrales críticos, y por otro, ofrece un criterio cuantitativo para evaluar la efectividad de las intervenciones, en función de la reducción observada del riesgo tras su ejecución.

De esta forma, la arquitectura de la metodología, recogida en la Figura 32, se estructura en seis etapas:

- A. Análisis de Modos de Fallo y Efectos (AMFE) y definición de modelos NOC.
- B. Entrenamiento de los modelos NOC y obtención del rango NOC de los residuos.
- C. Detección de desviaciones significativas.
- D. Construcción de las curvas de riesgo.
- E. Diagnóstico de las curvas de riesgo.
- F. Evaluación de impacto del mantenimiento.




Figura 32. Diagrama de bloques del método propuesto

A. Análisis de Modos de Fallo y Efectos (AMFE) y definición de modelos NOC

El primer paso consiste en realizar un Análisis de Modos de Fallos y Efectos (AMFE) del equipo objeto de estudio [1], [2]. Este análisis implica la identificación de todos los posibles fallos que pueden ocurrir en el equipo ($FM_i, i = 1, 2, \dots, m$, donde m es el número total de modos de fallo detectados), incluyendo sus efectos, su gravedad y los posibles métodos de detección asociados.

Para determinar dichos métodos de detección, es necesario identificar previamente las variables del equipo que están siendo monitorizadas ($X_j, j = 1, 2, \dots, p$, donde p es el número de variables medidas), ya que esto permite construir un mapa relacional entre las variables observables y los modos de fallo (ver Figura 33).

La integración de este mapa con el conocimiento experto facilita la definición de los modelos necesarios para monitorizar la aparición de cada modo de fallo. En particular, permite establecer cuáles serán las variables de salida de dichos modelos ($Y_k, k = 1, 2, \dots, Q \geq m$, donde Q es el número total de modelos definidos y $Y_k \in \{X\}$). Según el método de detección propuesto, puede haber modelos que compartan la misma variable de salida, uno o varios modelos por modo de fallo, o incluso un mismo modelo que contribuya a la detección de distintos fallos.

Las variables de entrada de cada modelo [$X_s^{(k)}, k \in [1, Q], s = 1, 2, \dots, p_k < p$, donde X_s es la s -ésima variable de entrada, k es el número de modelo y p_k es el número de variables de entrada del modelo k] se seleccionan de entre el conjunto de variables monitorizadas ($X_s^k \in \{X\}$), en función del conocimiento físico del fenómeno a detectar y de las relaciones funcionales entre variables.




Figura 33. Diagrama de bloques de la definición de los modelos basada en el AMFE

B. Entrenamiento de los modelos NOC y obtención del rango NOC de los residuos

Una vez definidos los Q modelos, se recopilan datos históricos correspondientes a condiciones normales de operación del equipo, denotados como $\{X\}_{\text{NOC}}$, que se emplean para entrenar dichos modelos. De esta manera, cuando los modelos reciben nuevos valores de sus variables de entrada ($\{X^{(k)}\}_{\text{new}}$), generan como salida el valor esperado de la variable monitorizada bajo condiciones normales, representado como $Y_{\text{NOC}}^{(k)}$. Es por este motivo que estos modelos se conocen como modelos NOC. En conjunto, estos modelos conforman el Gemelo Digital y permiten simular el comportamiento normal esperado del equipo.

Para monitorizar cuantitativamente el comportamiento real del equipo, se compara el valor observado con el valor esperado de las variables. Es decir, se calcula la diferencia (residuo) entre el valor real y el valor simulado por el modelo:

$$E^{(k)}(t) = Y^{(k)}(t) - Y_{\text{NOC}}^{(k)}(t) \quad (1)$$

donde t es la variable temporal que representa la muestra analizada.

Para que estas diferencias sean una fuente útil de información, es necesario caracterizar el comportamiento normal de las salidas de los modelos, lo cual se realiza analizando sus residuos durante el entrenamiento. Se ajusta una función de distribución a los residuos obtenidos, $P(E^{(k)})$, y se define un intervalo de confianza para el comportamiento considerado normal:

$$CI_{NOC}^{(k)} = [L_{inf}^{(k)}, L_{sup}^{(k)}] \quad (2)$$

De esta forma, al recibir un nuevo valor de la variable de salida de un modelo, se calcula el residuo entre el valor real y el valor simulado. Si el residuo se encuentra dentro del intervalo de confianza, se concluye que la variable se comporta de forma normal:

$$E^{(k)}(t) = Y^{(k)}(t) - Y_{NOC}^{(k)}(t)$$

$$E^{(k)}(t) \in CI_{NOC}^{(k)} \rightarrow Y^{(k)}(t) \text{ se comporta de forma normal} \quad (3)$$

Una de las principales ventajas de esta metodología es que no requiere datos históricos de fallos para entrenar modelos capaces de identificar patrones anómalos, superando una de las limitaciones habituales de los métodos clásicos de clasificación en diagnóstico de fallos [3], [4], [5].

En su lugar, el objetivo es entrenar modelos de regresión que generalicen el comportamiento normal utilizando únicamente datos históricos de operación normal. Como los valores reales bajo condiciones normales actúan como etiquetas, es posible aplicar algoritmos de aprendizaje supervisado de manera directa y fiable.

C. Detección de desviaciones significativas

Por el contrario, si el residual se encuentra fuera del intervalo de confianza especificado, puede inferirse que el valor de la variable es anómalo:

$$E^{(k)}(t) \notin CI_{NOC}^{(k)} \rightarrow Y^{(k)}(t) \text{ es anómalo} \quad (4)$$

En caso de identificarse C o más valores anómalos consecutivos, la variable se clasifica como que presenta una desviación del comportamiento normal. En consecuencia, el modo de fallo asociado a la variable puede considerarse como que está presentando un riesgo creciente de ocurrencia, que es inminente o que ya ha ocurrido.

La decisión de fijar un umbral de C valores atípicos se basa en la experiencia acumulada. Si se identifican menos de C valores anómalos, se consideran como ruido, falsos positivos o desviaciones esporádicas no relevantes, y no se incorporan al análisis. Esto se debe a la expectativa de que, en caso de fallo o evento crítico, se verá reflejado en un comportamiento anómalo sostenido en el tiempo, y no en una anomalía repentina.

El valor de muestras anómalas consecutivas, C , es un parámetro ajustable de la metodología, y depende de cada caso particular.

Las desviaciones se calculan como uno más el valor absoluto de la distancia del residual al extremo del intervalo de confianza del mismo signo, dividido entre el valor de dicho extremo:

$$\left\{ \begin{array}{ll} \text{DEV}^{(k)}(t) = 1 + \frac{|E^{(k)}(t) - L_{\inf}^{(k)}|}{|L_{\inf}^{(k)}|} & \text{if } E^{(k)}(t) < L_{\inf}^{(k)} \\ \text{DEV}^{(k)}(t) = 0 & \text{if } E^{(k)} \in [L_{\inf}^{(k)}, L_{\sup}^{(k)}] \\ \text{DEV}^{(k)}(t) = 1 + \frac{|E^{(k)}(t) - L_{\sup}^{(k)}|}{|L_{\sup}^{(k)}|} & \text{if } E^{(k)}(t) > L_{\sup}^{(k)} \end{array} \right. \quad (5)$$

El valor uno es simplemente un valor arbitrario para indicar que el residual está justo en el límite para considerarse una desviación. La división por el límite del intervalo de confianza se usa para obtener una medida normalizada, asegurando que las desviaciones normalizadas obtenidas de cada modelo sean comparables.

D. Construcción de las curvas de riesgo

El concepto de curva de riesgo juega un papel fundamental en la metodología propuesta, ya que constituye el indicador de fallo propuesto. La construcción de estas curvas implica la generación de curvas de riesgo para los modelos NOC previos. Para cada uno de estos modelos, la curva de riesgo, $f(t)$, se crea calculando la suma acumulada de desviaciones normalizadas detectadas a lo largo del tiempo. Al agregar estas desviaciones, la curva de riesgo captura la evolución y persistencia de anomalías en el comportamiento del equipo:

$$f^{(k)}(t) = \sum_{n=t_0}^t \text{DEV}^{(k)}(n) \quad (6)$$

donde t_0 es el tiempo de referencia, es decir, el correspondiente a la primera muestra disponible.

Dado que un mismo modo de fallo puede influir sobre múltiples variables de operación, la curva de riesgo para un modo de fallo dado se obtiene como una suma ponderada de las curvas de riesgo de los modelos NOC relevantes. Los pesos reflejan la importancia relativa de cada variable en la monitorización de dicho modo de fallo. Determinados en consulta con expertos, estos pesos se normalizan para que su suma sea igual a uno:

$$f^{(i)}(t) = \sum_k \omega_k f^{(k)}(t) \quad (7)$$

$$\sum_k \omega_k = 1 \quad (8)$$

donde i es el modo de fallo considerado, k recorre los modelos NOC utilizados para monitorizarlo y $\omega_k > 0$.




Figura 34. Diagrama de flujo detallado de la metodología propuesta

Para ofrecer una visión global de la metodología, la Figura 34 presenta una representación visual detallada de todo el proceso, desde la adquisición de nuevas muestras de datos y el cálculo de los residuos, hasta la construcción y agregación de las curvas de riesgo, y finalmente, la evaluación de la eficacia del mantenimiento.

Este diagrama complementa las ecuaciones y procedimientos descritos en las subsecciones B a D, y también ilustra cómo estos pasos se conectan con las etapas de evaluación presentadas en las subsecciones E y F, conformando así un sistema continuo de monitorización y soporte a la toma de decisiones.

E. Diagnóstico de las curvas de riesgo

Como sugiere el término, las curvas de riesgo se utilizan para cuantificar la proximidad de la ocurrencia de un modo de fallo específico: a mayor riesgo, más cercana y probable es su ocurrencia. Dado que la medida del riesgo es relativa, el umbral máximo de riesgo para cada modo de fallo se determina con base en casos históricos de fallo. Es decir, se construye la curva de riesgo pasada y se identifica el nivel de riesgo que existía cuando ocurrió el fallo. Este valor puede entonces usarse como umbral máximo para eventos futuros, $f_{\max}^{(i)}$.

Si se identifican múltiples casos históricos con diferentes niveles máximos de riesgo, debe elegirse el más bajo para mantener una evaluación conservadora, evitando así sobrestimar la criticidad del fallo.

Incluso en ausencia de datos históricos, la curva de riesgo sigue siendo útil:

- A nivel cualitativo, muestra la evolución del riesgo en el tiempo.
- A nivel cuantitativo, sirve como indicador para calcular la eficacia de acciones de mantenimiento, como se verá en la siguiente sección.

Por lo tanto, una vez construidas las curvas de riesgo para todos los modos de fallo, basta con analizar dos aspectos:

1. El nivel de riesgo actual y su proximidad al umbral máximo: $|f_{\max}^{(i)} - f^{(i)}(t)|$.
2. La pendiente de la curva entre dos muestras t_1 y t_2 ($t_2 > t_1$), $\Delta f^{(i)}(t)/\Delta t|_{t_1}^{t_2}$, que indica la rapidez con la que evoluciona el riesgo.

Si la pendiente de una curva de riesgo es cero, esto indica que, con respecto al modo de fallo correspondiente, el equipo ha retornado a un comportamiento normal. Además, aunque el valor del riesgo pueda haber aumentado previamente, si dicho valor se encuentra lejos del umbral máximo establecido para ese modo de fallo, todavía existe margen para realizar acciones de mantenimiento, en caso de considerarse necesario. Por el contrario, si la pendiente de la curva de riesgo es constantemente positiva, lo que indica un aumento continuo en el riesgo, es muy probable que el equipo haya sufrido algún tipo de daño que está afectando de forma persistente al modo de fallo correspondiente. En este caso, se requiere una intervención de mantenimiento inmediata.

$$\begin{cases} \Delta f^{(i)}(t)/\Delta t|_{t_1}^{t_2} = 0 & \rightarrow \text{Comportamiento normal} \\ \Delta f^{(i)}(t)/\Delta t|_{t_1}^{t_2} > 0 & \rightarrow \text{Anomalía en progreso} \end{cases}$$

F. Evaluación de impacto del mantenimiento

Finalmente, las curvas de riesgo son una herramienta valiosa para evaluar la efectividad de una intervención de mantenimiento, ya que actúan como indicadores de fallo. Esencialmente, el impacto de una intervención de mantenimiento, a , puede cuantificarse comparando la curva de riesgo del modo de fallo k antes ($t_{\text{bef}} < t_a$) y después ($t_{\text{aft}} > t_a$) de la acción:

$$ef_a = 1 - \frac{\Delta f^k/\Delta t|_{t_a}^{t_{\text{aft}}}}{\Delta f^k/\Delta t|_{t_{\text{bef}}}^{t_a}} \quad (9)$$

donde t_a es el momento en que se realiza la intervención de mantenimiento.

Si la efectividad obtenida es positiva, significa que después de la acción de mantenimiento el riesgo del modo de fallo considerado está creciendo más lentamente que antes de la acción o incluso ha dejado de crecer ($ef_a = 1$). Esto significa que el mantenimiento realizado ha sido efectivo, y la magnitud de dicha efectividad está determinada por el valor de efectividad obtenido.

Por otro lado, si la efectividad obtenida es cero, significa que después de la acción de mantenimiento el riesgo continúa creciendo al mismo ritmo que antes, es decir, la acción de mantenimiento realizada no tuvo impacto, fue irrelevante para la solución del problema.

Por el contrario, si la efectividad obtenida es negativa, significa que el riesgo está creciendo más rápido después de la acción que antes. Esto significa que la acción tomada no solo fue ineficaz, sino que en realidad empeoró la situación.

En consecuencia, puede realizarse una evaluación de la efectividad de un conjunto de acciones de mantenimiento, lo que permite determinar si han sido beneficiosas, para qué modos de fallo lo han sido y, en tal caso, en qué medida.

5.2.3 Caso de estudio

Con el objetivo de validar la metodología desarrollada en un entorno industrial real, se ha llevado a cabo su aplicación a una bomba de agua de alimentación perteneciente al ciclo agua-vapor de una central de ciclo combinado operada por ENDESA. Este activo fue seleccionado debido a su criticidad operativa, su elevado número de variables monitorizadas y la disponibilidad de un histórico extenso de datos de operación y mantenimiento.

El caso de estudio permite ilustrar de manera práctica cada una de las fases del método, desde el AMFE inicial hasta la evaluación cuantitativa del impacto de las intervenciones realizadas. Además, ofrece una validación empírica del concepto de “curva de riesgo” como indicador de fallo y herramienta de diagnóstico y seguimiento de la salud del equipo.

Los datos utilizados abarcan un periodo de cuatro años (2019-2023), incluyendo tanto variables operativas registradas por los sistemas de control de planta como los registros de mantenimiento correctivo y preventivo realizados sobre el equipo. La metodología se ha aplicado en su totalidad sobre este conjunto de datos, demostrando su viabilidad técnica, su capacidad diagnóstica y su potencial para optimizar la gestión del mantenimiento industrial en entornos reales.

A. Análisis de Modos de Fallo y Efectos (AMFE) y definición de modelos NOC

De acuerdo con la metodología, el primer paso consiste en realizar un AMFE de la bomba de alimentación, identificando los posibles modos de fallo y sus manifestaciones observables. A partir de este análisis y del conocimiento experto aportado por ENDESA, se definen los modelos predictivos necesarios para monitorizar el comportamiento esperado de las variables relevantes bajo condiciones normales de operación. Esta etapa permite establecer un mapa relacional entre variables y modos de fallo (Figura 35), base sobre la cual se construye la arquitectura del sistema de detección de anomalías.




Figura 35. Mapa relacional entre modos de fallo y variables monitorizadas basado en el AMFE

Así pues, tal como se ha explicado, este mapa facilita la identificación de qué variables permiten detectar cada uno de los modos de fallo, y, por tanto, la definición de los modelos NOC necesarios para la detección de anomalías. Teniendo en cuenta las variables monitorizadas, se han definido m=9 modos de fallo y Q=23 modelos NOC. La Tabla 1 establece la relación entre los modos de fallo y cada uno de los modelos definidos. Como puede observarse, un mismo modelo puede utilizarse para monitorizar varios modos de fallo, y un único modo de fallo puede requerir la utilización de más de un modelo para su correcta detección.

Modo de fallo	Variable de salida del modelo NOC
Sobrecarga del motor (FM ₁)	Corriente Fase R (M ₂)
	Corriente Fase S (M ₃)
	Corriente Fase T (M ₄)
	Corriente Fase R (M ₈)
	Corriente Fase S (M ₉)
	Corriente Fase T (M ₁₀)
Desgaste del cojinete LAOM (FM ₂)	Temp. cojinete LAOM (M ₂₂)
Desgaste del cojinete LAM (FM ₃)	Temp. cojinete LAM (M ₂₁)
Desgaste del cojinete LAOB (FM ₄)	Desplazamiento Dir1 cojinete LAOB (M ₁₆)
	Desplazamiento Dir2 cojinete LAOB (M ₁₇)
	Temp. cojinete LAOB (M ₂₀)
Desgaste del cojinete LAB (FM ₅)	Desplazamiento Dir1 cojinete LAB (M ₁₄)
	Desplazamiento Dir2 cojinete LAB (M ₁₅)
	Temp. cojinete LAB (M ₁₉)
Desgaste del cojinete de empuje (FM ₆)	Vibración cojinete de empuje (M ₁₈)
	Temp. cojinete de empuje (M ₂₃)
Fuga (FM ₇)	Caudal de descarga (M ₁)
	Corriente Fase R (M ₈)
	Corriente Fase S (M ₉)
	Corriente Fase T (M ₁₀)
Eje desalineado (FM ₈)	Desplazamiento Dir1 cojinete LAB (M ₁₄)
	Desplazamiento Dir2 cojinete LAB (M ₁₅)
	Desplazamiento Dir1 cojinete LAOB (M ₁₆)
	Desplazamiento Dir2 cojinete LAOB (M ₁₇)
	Vibración cojinete de empuje (M ₁₈)
	Temp. cojinete LAB (M ₁₉)
	Temp. cojinete LAOB (M ₂₀)
	Temp. cojinete LAM (M ₂₁)
	Temp. cojinete LAOM (M ₂₂)
	Temp. cojinete de empuje (M ₂₃)
Fallo eléctrico en el motor (FM ₉)	Corriente Fase R (M ₂)
	Corriente Fase S (M ₃)
	Corriente Fase T (M ₄)
	Temp. Fase R (M ₅)
	Temp. Fase S (M ₆)
	Temp. Fase T (M ₇)
	Corriente Fase R (M ₈)
	Corriente Fase S (M ₉)
	Corriente Fase T (M ₁₀)
	Temp. Fase R (M ₁₁)
	Temp. Fase S (M ₁₂)
	Temp. Fase T (M ₁₃)

Tabla 1. Relación entre los modos de fallo y los modelos NOC del equipo

Con el fin de ilustrar el desarrollo paso a paso del método, se ha seleccionado uno de los modelos como ejemplo. No obstante, cabe destacar que el procedimiento es idéntico para el resto de los modelos. El modelo elegido es el “Modelo de Caudal de Descarga”, que predice el comportamiento normal del caudal de salida de la bomba. Este modelo se utiliza para monitorizar posibles modos de fallo como las fugas de agua.

Las variables de entrada del modelo son la corriente media del motor que acciona la bomba y la potencia de la turbina de gas asociada a la caldera de dicha bomba como se muestra en la Figura 36:




Figura 36. Diagrama de bloques del modelo NOC del caudal de descarga

B. Entrenamiento de los modelos NOC y obtención del rango NOC de los residuos

Una vez definidos los modelos, se procede al entrenamiento supervisado utilizando datos históricos correspondientes a periodos de operación normal del equipo. Esta fase tiene como objetivo generar una representación precisa del comportamiento normal esperado de las variables monitorizadas.

Así pues, el primer paso consiste en la recolección de un conjunto de datos correspondientes a un periodo representativo de condiciones normales de operación, es decir, un periodo en el que la bomba opera a lo largo de todo su rango de funcionamiento (exceptuando los modos transitorios), sin registrar incidencias ni intervenciones de mantenimiento relevantes.

El conjunto de datos utilizado en este estudio abarca un periodo de cuatro años, desde diciembre de 2019 hasta diciembre de 2023. La Figura 37 muestra los datos recopilados del caudal de descarga (los huecos sin datos corresponden a periodos en los que la bomba no estaba en funcionamiento).




Figura 37. Datos históricos del caudal de descarga

Y, utilizando la información de mantenimiento proporcionada por ENDESA, se ha determinado un periodo representativo de comportamiento normal, que abarca desde diciembre de 2019 hasta julio de 2020 (puntos naranjas en la Figura 38). El resto de los datos se usan para validar el resto de la metodología.




Figura 38. Periodo NOC identificado en los datos históricos del caudal de descarga

La selección del algoritmo de aprendizaje automático supervisado y la optimización de sus hiperparámetros se lleva a cabo mediante un proceso iterativo, que consiste en entrenar el modelo múltiples veces con diferentes configuraciones y algoritmos. Para la selección, se comparan los resultados obtenidos con los de algoritmos ampliamente utilizados en tareas de regresión, como la regresión lineal (LR), k-Nearest Neighbour (kNN), árboles de decisión (DT), máquinas de vectores de soporte (SVM) y perceptrones multicapa (MLP) [6], [7], [8], [9].

La métrica utilizada para evaluar el rendimiento es el error cuadrático medio (RMSE), uno de los indicadores más comunes en modelos de regresión.

En el caso particular del Modelo de Caudal de Descarga el algoritmo que ofrece los mejores resultados es el perceptrón multicapa (MLP). Tanto los hiperparámetros óptimos como los resultados del entrenamiento y validación se recogen la Tabla 2.

Modelo NOC del caudal de descarga	
Algoritmo	Perceptrón multicapa (MLP)
Función de activación	ReLu
Neuronas de las capas ocultas	12, 14
Tasa de aprendizaje inicial	0.0056
Tipo de tasa de aprendizaje	Adaptativo
Solver	Adam
Alpha	0.0001
Fracción de validación	0.2
Iteraciones máximas	10000
RMSE (Entrenamiento)	1.4377 T/h
RMSE (Validación)	1.4589 T/h

Tabla 2. Hiperparámetros del modelo NOC del caudal de descarga

Tras el entrenamiento, si este ha sido exitoso, los residuos del conjunto de entrenamiento deberán seguir una distribución similar a una distribución normal con media cero (ver Figura 39).

Dado que, tal como se ha explicado en la metodología, el objetivo de estos modelos es caracterizar el comportamiento normal de sus variables de salida. A continuación, se realiza un análisis de la distribución de los residuos del entrenamiento, a partir del cual se calcula el intervalo de confianza asociado al comportamiento normal de la variable de salida.

De esta forma, la distribución de estos residuos se ajusta utilizando la técnica "Gaussian Mixture Model (GMM)" (ver Figura 40). Y, de acuerdo con la regla empírica de la estadística (regla 68-95-99.7), se selecciona un intervalo de confianza del 99,7 % (ver Figura 41).




Figura 39. Distribución de los residuos de entrenamiento del modelo NOC del caudal de descarga




Figura 40. Ajuste de la distribución de los residuos de entrenamiento del modelo NOC del caudal de descarga mediante GMM




Figura 41. Caracterización del comportamiento normal del caudal de descarga mediante la definición del intervalo NOC de confianza

C. Detección de desviaciones significativas

Una vez caracterizado el comportamiento normal de la bomba mediante el intervalo de confianza, este se utiliza para detectar posibles desviaciones significativas en el conjunto completo de datos históricos.

La Figura 42 muestra las desviaciones significativas detectadas (con $C = 3$) en el caudal de descarga de la bomba, calculadas según la ecuación. (5)




Figura 42. Desviaciones del caudal de descarga durante el periodo de datos históricos

D. Construcción de las curvas de riesgo

Usando la ecuación (6), se construye la curva de riesgo del caudal de descarga de la bomba (ver Figura 43).




Figura 43. Curva de riesgo del caudal de descarga de la bomba

Tal como se indicó en la metodología, el objetivo es monitorizar el riesgo asociado a cada modo de fallo, y no el de cada modelo individualmente. Esto se debe a que un mismo modo de fallo puede manifestarse en varias variables del equipo. En consecuencia, tal como se establece en la ecuación (7), se construyen curvas de riesgo específicas para cada modo de fallo.

La Figura 44 muestra la relación entre los modos de fallo y los modelos, según lo expuesto en la Tabla 1, así como los pesos asignados a cada modelo para el cálculo del riesgo correspondiente a cada modo de fallo.




Figura 44. Mapa relacional entre los modos de fallo y los modelos del equipo

Para ilustrar este proceso, se toma como ejemplo el modo de fallo "Fuga". Según los expertos en mantenimiento, los modelos implicados en este modo de fallo son aquellos que predicen el caudal de descarga (Modelo de Caudal de Descarga) y las corrientes de las fases del motor de la bomba (Modelo de Corriente Fase R, Modelo de Corriente Fase S y Modelo de Corriente Fase T).

Los pesos asignados a cada uno de estos modelos son los siguientes: 0.55, 0.15, 0.15 y 0.15, respectivamente (ver Figura 44). Se observa claramente que los pesos cumplen con la ecuación (8).

Las curvas de riesgo asociadas a todos los modos de fallo considerados en el AMFE se muestran en la Figura 45 y la Figura 46, una vez aplicado el procedimiento completo descrito anteriormente a cada uno de los modelos y modos de fallo.




Figura 45. Curvas de riesgo de todos los modos de fallo bajo análisis




Figura 46. Curvas de riesgo de todos los modos de fallo bajo análisis (ampliación)

E. Diagnóstico de las curvas de riesgo

De acuerdo con la metodología, en esta sección se presenta un análisis de las curvas de riesgo asociadas a cada uno de los modos de fallo.

La Figura 46 muestra que el incremento más significativo en el riesgo está asociado a los modos de fallo “Desgaste del cojinete LAOB” (curva roja) y “Desgaste del cojinete LAB” (curva púrpura). Estas curvas reflejan un aumento pronunciado y sostenido del riesgo, que comenzó en septiembre de 2020 y alcanzó un nivel notablemente elevado. Esto indica que se ha producido un problema significativo, haciendo altamente probable la ocurrencia de un fallo, o incluso sugiriendo que este ya se ha materializado. Al revisar los registros del taller, se confirmó que efectivamente se detectó un fallo en el cojinete a mediados de septiembre.

Este fallo provocó un aumento notable de las vibraciones en el cojinete LAOB, que posteriormente se propagaron al cojinete LAB. Además, puede deducirse razonablemente que dichas vibraciones derivan inevitablemente en un aumento del riesgo asociado al modo de fallo “Eje desalineado” (curva gris).

El riesgo asociado al desgaste de los otros tres cojinetes también aumentó en septiembre de 2020 como consecuencia del problema en el cojinete LAOB, aunque en menor medida. No obstante, se observó un nuevo incremento sustancial del riesgo en la segunda mitad de 2022, coincidiendo con otro aumento en los riesgos de los cojinetes LAOB y LAB. Esto sugiere que se estaba desarrollando o ya se había producido un fallo que afectaba al conjunto de las vibraciones de la bomba, si bien determinar la causa exacta resulta complejo.

Otra curva relevante es la asociada al riesgo de “Fuga” (curva rosa de la Figura 46), que comenzó a incrementarse en agosto de 2021 y se intensificó abruptamente a partir de agosto de 2022. Esto indicaba la posible presencia de una fuga. En efecto, los registros del taller confirmaron que una fuga fue detectada y reparada en agosto de 2022. Este caso resulta especialmente significativo, ya que no solo demuestra la eficacia del método de detección y diagnóstico para identificar fallos existentes, sino también su capacidad para detectarlos en fases muy tempranas, posibilitando una intervención proactiva.

Las curvas restantes están relacionadas con la fuga detectada, que provoca una sobrecarga del motor y alteraciones en sus corrientes. Esto se refleja en el incremento del riesgo observado en las curvas azul y amarilla, respectivamente. Septiembre de 2022 marcó el punto en que la fuga alcanzó su máxima severidad, tras haber ocasionado previamente un pico de riesgo en el modo de fallo “Fallo eléctrico del motor”. Este desequilibrio en las corrientes suele derivar en un aumento de las vibraciones del motor, lo cual podría estar relacionado con el incremento de vibraciones detectado en agosto de 2022 en los tres cojinetes menos afectados por el fallo del LAOB. No obstante, esto último no es más que una hipótesis.

F. Evaluación de impacto del mantenimiento

La utilidad de las curvas de riesgo va más allá de la detección y diagnóstico de fallos, ya que también proporcionan una plataforma para superponer las acciones de mantenimiento realizadas a lo largo del tiempo. Esto permite obtener dos beneficios clave: en primer lugar, la comparación de los resultados del análisis; y, en segundo lugar, la evaluación de la efectividad de las acciones de mantenimiento para cada modo de fallo.

La Figura 47 muestra las curvas de riesgo junto con las fechas en las que se han ejecutado acciones de mantenimiento preventivo sobre el equipo (líneas verticales azules), que consisten en una revisión general de temperaturas, vibraciones y fugas, un cambio general de aceite y una inspección de corrosión. Estas acciones se realizan cada dos meses, independientemente del estado de la bomba, y por tanto no están orientadas a verificar si se ha producido un modo de fallo específico que requiera mantenimiento inmediato.

Por el contrario, la Figura 48 muestra las curvas de riesgo junto con las fechas en las que se han ejecutado acciones de mantenimiento correctivo (líneas verticales negras), las cuales solo se llevan a cabo cuando algún componente de la bomba requiere reparación o sustitución.

En el caso analizado, se puede verificar que se realizó una acción de mantenimiento correctivo a principios de septiembre de 2020, que consistió en la sustitución del cojinete LAOB roto y el ajuste del resto de los cojinetes y del eje. El resto de las acciones se componen principalmente de cambios de aceite, rellenados y ajustes menores en los cojinetes de la bomba.




Figura 47. Hitos de mantenimiento preventivo superpuestos a las curvas de riesgo de los modos de fallo del equipo




Figura 48. Hitos de mantenimiento correctivo superpuestos a las curvas de riesgo de los modos de fallo del equipo

Como se anticipaba, estas curvas permiten evaluar la eficacia de las acciones de mantenimiento realizadas. Para ello, es necesario aplicar la ecuación (9) a las fechas en las que se llevaron a cabo dichas acciones.

Con el fin de ilustrar los conceptos expuestos, se analizan dos ejemplos concretos. En primer lugar, se examina la curva roja, correspondiente al modo de fallo “Desgaste del cojinete LAOB”, y la acción de mantenimiento correctivo realizada a finales de noviembre de 2021, t_a (Figura 48). Suponiendo que los instantes inicial y final se definen como $t_{bef} = t_a - \Delta t$ y $t_{aft} = t_a + \Delta t$, respectivamente, con Δt igual a una semana, se obtiene que la eficacia del mantenimiento realizado es del 73 %. Sin embargo, si se considera la curva marrón (“Desgaste del cojinete de empuje”), la eficacia es del 0 %.

También es posible realizar un análisis cualitativo de la eficacia de las acciones de mantenimiento a simple vista. Se observa claramente que las tres últimas acciones de mantenimiento correctivo han tenido un impacto en los modos de fallo “Desgaste del cojinete LAOB”, “Desgaste del cojinete LAB” y “Eje desalineado”. Antes de estas acciones, las curvas de riesgo presentaban una pendiente positiva, mientras que, tras su ejecución, la pendiente se estabiliza en cero. En cualquier caso, parece que el problema en el cojinete LAOB tiene un origen adicional, ya que su curva de riesgo sigue creciendo de forma gradual, y las distintas acciones de mantenimiento realizadas solo generan un efecto positivo temporal.

A continuación, se analiza la acción de mantenimiento preventivo programada para octubre de 2023 y la curva rosa, correspondiente al modo de fallo “Fuga” (Figura 48). En este caso, la eficacia es del 100 %, lo que indica que la fuga fue subsanada tras la intervención. Sin embargo, esta misma acción no tiene efecto perceptible sobre los modos de fallo “Desgaste del cojinete LAOB”, “Desgaste del cojinete LAB” ni “Eje desalineado”.

Este proceso se ha repetido para todas las acciones de mantenimiento y para cada uno de los modos de fallo, lo que ha permitido determinar la efectividad individual de cada acción en cada caso.

Así pues, este análisis, junto con el diagnóstico obtenido a partir de las curvas de riesgo, permite extraer una serie de conclusiones que contribuyen a la optimización del mantenimiento y, en consecuencia, a la prolongación de la vida útil del equipo:

1. El fallo del cojinete LAOB comienza a manifestarse en su curva de riesgo asociada en abril de 2020, pero no es detectado en planta hasta el 15 de septiembre de 2020, es decir, con cinco meses de antelación.
2. La fuga comienza a reflejarse en su curva de riesgo en octubre de 2021, mientras que no se detecta en planta hasta el 7 de febrero de 2022, con una anticipación de cuatro meses. Además, se observa que la reparación no fue efectiva hasta que se realizó mantenimiento preventivo en octubre de 2022.
3. La efectividad de cada una de las acciones de mantenimiento demuestra claramente que algunas son más efectivas que otras, y específicamente para ciertos modos de fallo concretos.

4. La eficacia media de las acciones de mantenimiento preventivo para cada modo de fallo es aproximadamente del 30 %. Por tanto, resulta imprescindible revisar en profundidad las tareas realizadas con el objetivo de optimizar su efectividad.

Todo ello pone de manifiesto la importancia del método propuesto, ya que habría permitido ahorrar tiempo y costes significativos mediante la detección temprana de fallos. Además, el análisis cuantitativo de las acciones de mantenimiento permite al personal identificar y eliminar tareas ineficaces, facilitando así una toma de decisiones más precisa y mejorando la eficiencia operativa. Esto se traduce, en última instancia, en una mayor vida útil del equipo y en un ahorro económico y operativo considerable.

5.2.4 Conclusiones

Esta primera fase de la investigación desarrollada en el marco de la Cátedra ha permitido definir y validar una metodología innovadora para la evaluación de la efectividad del mantenimiento en sistemas industriales, basada en el concepto de curvas de riesgo como indicadores cuantitativos del estado de salud de los equipos.

Mediante la integración del AMFE con modelos de detección de anomalías basados en aprendizaje automático, el método propuesto permite una monitorización en tiempo real del estado de salud de los equipos, así como una evaluación precisa de las acciones de mantenimiento.

La metodología propuesta representa un avance significativo en la evaluación del mantenimiento, aportando contribuciones tanto técnicas como prácticas a la gestión industrial. Al abordar los desafíos identificados y continuar optimizando el enfoque, este “framework” tiene el potencial de convertirse en un pilar fundamental para las prácticas de mantenimiento predictivo y prescriptivo.

Su capacidad para detectar fallos de forma temprana, evaluar cuantitativamente la efectividad del mantenimiento y facilitar una toma de decisiones informada puede mejorar sustancialmente la fiabilidad de los equipos, fomentar una mejor colaboración entre los equipos de operación y mantenimiento, reducir costes y apoyar una gestión sostenible de los activos industriales.

El enfoque combina el Análisis de Modos de Fallo y Efectos (AMFE) con modelos de detección de anomalías basados en aprendizaje automático, permitiendo así una monitorización continua y en tiempo real del comportamiento de los activos. Esta metodología proporciona una visión objetiva del impacto de cada intervención de mantenimiento, facilitando la toma de decisiones informada y basada en datos.

El método propuesto constituye un avance significativo tanto en el plano técnico como en el operativo, al ofrecer una herramienta capaz de:

- Detectar fallos de forma temprana, antes de que se manifiesten de manera crítica.
- Evaluar cuantitativamente la efectividad de las acciones de mantenimiento, diferenciando entre intervenciones correctivas y preventivas.
- Optimizar las estrategias de mantenimiento, al permitir revisar y ajustar tareas preventivas con baja efectividad.
- Mejorar la coordinación entre operación y mantenimiento, gracias a una representación visual común del riesgo y del efecto de las intervenciones.

Este nuevo enfoque cubre una brecha existente en la evaluación del mantenimiento, abriendo nuevas posibilidades para la mejora continua de la condición de los activos industriales, y contribuyendo a una mayor eficiencia operativa y a la reducción de costes.

Además, la metodología desarrollada supone un avance importante en la digitalización de la toma de decisiones, al integrarse de forma natural con las herramientas y plataformas digitales ya en desarrollo por ENDESA. La Figura 49 presenta un ejemplo de esta integración al mostrar el cuadro de mando propuesto para la herramienta GMTwin.

En conjunto, como ya se ha mencionado en la introducción, esta primera fase constituye la base diagnóstica de un “framework” más amplio, cuyo objetivo final es establecer una plataforma predictiva y prescriptiva para la gestión del mantenimiento, conectada con los sistemas de gestión de activos y repuestos, y capaz de generar un plan de mantenimiento óptimo a futuro. Este enfoque integral reforzará aún más la sostenibilidad, disponibilidad y eficiencia de los procesos industriales.



Figura 49. Ejemplo del cuadro de mando de la solución GMTwin

5.2.5 Referencias

- [1] Z. Sajaradj, L. N. Huda, and S. Sinulingga, “The Application of Reliability Centered Maintenance (RCM) Methods to Design Maintenance System in Manufacturing (Journal Review),” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 505, no. 1, p. 012058, May 2019, doi: 10.1088/1757-899X/505/1/012058.
- [2] D. Singh and A. Suhane, “Study of Centrifugal Pump Using Failure Mode Effect and Critical Analysis Based on Fuzzy Cost Estimation: A Case Study,” vol. 4, no. 7, 2013.
- [3] Y. Xu, Y. Sun, J. Wan, X. Liu, and Z. Song, “Industrial Big Data for Fault Diagnosis: Taxonomy, Review, and Applications,” *IEEE Access*, vol. 5, pp. 17368–17380, 2017, doi: 10.1109/ACCESS.2017.2731945.

- [4] Y. Zhao, T. Li, X. Zhang, and C. Zhang, "Artificial intelligence-based fault detection and diagnosis methods for building energy systems: Advantages, challenges and the future," *Renew. Sustain. Energy Rev.*, vol. 109, pp. 85–101, Jul. 2019, doi: 10.1016/j.rser.2019.04.021.
- [5] F. Calabrese, A. Regattieri, M. Bortolini, and F. G. Galizia, "Data-Driven Fault Detection and Diagnosis: Challenges and Opportunities in Real-World Scenarios," *Appl. Sci.*, vol. 12, no. 18, Art. no. 18, Jan. 2022, doi: 10.3390/app12189212.
- [6] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 3, p. 160, Mar. 2021, doi: 10.1007/s42979-021-00592-x.
- [7] B. Mahesh, "Machine Learning Algorithms - A Review," *Int. J. Sci. Res. IJSR*, vol. 9, no. 1, pp. 381–386, Jan. 2020, doi: 10.21275/ART20203995.
- [8] Babcock University et al., "Supervised Machine Learning Algorithms: Classification and Comparison," *Int. J. Comput. Trends Technol.*, vol. 48, no. 3, pp. 128–138, Jun. 2017, doi: 10.14445/22312803/IJCTT-V48P126.
- [9] M. M. Ali, B. K. Paul, K. Ahmed, F. M. Bui, J. M. W. Quinn, and M. A. Moni, "Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison," *Comput. Biol. Med.*, vol. 136, p. 104672, Sep. 2021, doi: 10.1016/j.combiomed.2021.104672.

5.3 JORNADAS DE DIVULGACIÓN DE TRABAJOS DE INVESTIGACIÓN REALIZADOS POR ALUMNOS DE INGENIERÍA DE GRADO Y DE MÁSTER

De acuerdo a las directrices fundacionales de la Cátedra, el objetivo de estas Jornadas es realizar la divulgación de resultados obtenidos en distintos Trabajos de Fin de Grado, de Fin de Máster y de Doctorado. En todos ellos se han aplicado técnicas de Inteligencia Artificial para detectar y diagnosticar posibles anomalías en el comportamiento esperado en determinados procesos y componentes industriales reales que pueden servir de base para replantear o confirmar las actuales directrices de los planes de mantenimiento aplicados.

5.3.1 Evaluación de técnicas de Deep Learning para la detección de anomalías en máquinas rotativas. Trabajo de Fin de Grado

Autora: D.^a Carlota López Argote

Este trabajo evalúa técnicas de Deep Learning para la detección de anomalías en maquinaria rotativa. Se desarrollan modelos combinando aprendizaje profundo y aprendizaje profundo reforzado, logrando resultados prometedores. Los modelos propuestos ofrecen una herramienta eficiente y confiable para el seguimiento y mantenimiento predictivo en entornos industriales.

Introducción

En este proyecto se ha llevado a cabo una evaluación exhaustiva de diversas técnicas de Deep Learning (DL) para la detección de anomalías en máquinas rotativas, utilizando datos de sensores de vibración. La detección temprana de fallos en estas máquinas es fundamental para garantizar su operación y mantenimiento óptimos en entornos industriales, como las centrales de generación eléctrica.

El procesamiento de los datos de los sensores de vibración proporciona información valiosa para identificar patrones y señales de alarma que indican posibles fallos en las máquinas rotativas [1]. En este proyecto se han explorado diferentes enfoques y técnicas de DL, como redes neuronales convolucionales (CNN) y aprendizaje por refuerzo profundo (DRL), con el objetivo de desarrollar un modelo preciso y fiable para la detección de fallos.

Se han realizado pruebas y comparaciones exhaustivas para evaluar el rendimiento y la efectividad de cada modelo en la detección y clasificación de anomalías. El objetivo final es contar con un modelo de DL implementable en entornos industriales reales, mejorando así la seguridad, la confiabilidad y la eficiencia energética de las operaciones.

Este proyecto se justifica por la necesidad de superar las limitaciones de los enfoques tradicionales [2] de detección de fallos en máquinas rotativas y ofrecer soluciones más efectivas. La combinación de técnicas de DL, adaptabilidad a diferentes velocidades de rotación y enfoque en la eficiencia energética posiciona este proyecto como una propuesta atractiva y altamente beneficiosa para las empresas, contribuyendo al crecimiento económico, la competitividad industrial y la sostenibilidad ambiental.

Definición del proyecto

En este proyecto, se ha utilizado un conjunto de datos público con el propósito de entrenar y validar los modelos de DL para la detección de anomalías en maquinaria rotativa. Esto ha permitido utilizar los resultados obtenidos como benchmark y así poder realizar una comparación con estudios similares. Los datos utilizados en este trabajo provienen de un estudio realizado en la Universidad de Paderborn. [3]

El estudio aborda el procesamiento de datos, el desarrollo de modelos y el análisis de resultados obtenidos. Para visualizar de manera concisa el flujo de trabajo seguido en el proyecto, se ha incluido la Figura 50. A través de esta figura, se pueden observar de manera visual las etapas clave del proceso y su interconexión.




Figura 50 - Diagrama de flujo del desarrollo del proyecto

Para la realización de este trabajo se ha tomado la decisión de utilizar datos de todos los experimentos con el objetivo de diseñar un modelo que pueda aplicarse de manera generalizada a cualquier tipo de fallo. Se toma una muestra representativa del conjunto de datos, garantizando el equilibrio de las clases de fallo. Por otro lado, se emplean los datos de la señal de vibración ya que se espera que estos proporcionen un mayor rendimiento en los modelos y se transforman al espectro de la frecuencia para facilitar la identificación de patrones. Además de utilizar los datos de la señal de vibración, también se ha añadido la velocidad de rotación como dato de entrada en los modelos ya que influye en las frecuencias de la señal así que incluirla permite diseñar un modelo capaz de funcionar bajo diferentes configuraciones.

Una vez que los datos han sido procesados, se procede al desarrollo de diversos modelos de Deep Learning (DL) y Deep Reinforcement Learning (DRL) para la detección de anomalías en maquinaria. Estos modelos se entrenan utilizando el conjunto de datos obtenido y se evalúan utilizando datos de prueba independientes. Sin embargo, los detalles específicos de los modelos serán abordados en la siguiente sección.

Con estos enfoques y consideraciones, el proyecto busca implementar un sistema eficaz de detección de anomalías en maquinaria, utilizando modelos de DL y DRL entrenados con datos relevantes y representativos.

Descripción de los modelos

Se han diseñado tres modelos diferentes para abordar la detección de anomalías en maquinaria. Estos modelos son una Convolutional Neural Network (CNN), una Double Deep Q-Network (DDQN) como método de RL, y un modelo conjunto que combina los dos anteriores para construir un enfoque más robusto.

El primer modelo es una CNN, que ha demostrado ser altamente efectiva en el procesamiento de datos secuenciales, como pueden ser las señales de vibración de la maquinaria. La CNN utiliza capas convolucionales para extraer características relevantes de los datos de entrada y capas completamente conectadas para realizar la clasificación. La ventaja principal de la CNN es su capacidad para capturar patrones espaciales en los datos, lo que resulta especialmente útil para detectar anomalías en señales de vibración.

El segundo modelo es una DDQN, que es una variante del algoritmo de Q-Learning utilizado en RL. Esta técnica utiliza una red neuronal para tomar decisiones basadas en la información recopilada. En el contexto de la detección de anomalías en maquinaria rotativa, la DDQN se utiliza para analizar los datos y detectar posibles fallos o irregularidades en el funcionamiento de la maquinaria. Esta técnica es efectiva para adaptarse entornos dinámicos y tomar decisiones informadas sobre la presencia de anomalías.

Finalmente, se ha desarrollado un modelo conjunto que combina los beneficios de la CNN y la DDQN. Este modelo aprovecha las capacidades de la CNN para capturar patrones espaciales en los datos de vibración, y utiliza la DDQN para aprender las mejores acciones a tomar en función de las características extraídas por la CNN. Al combinar estos dos enfoques, se logra un modelo más robusto y preciso en la detección de anomalías en maquinaria rotativa.

Para una mejor comprensión de la estructura y el diseño del modelo conjunto, se incluye la Figura 51, que ilustra de manera visual el proceso seguido para el desarrollo del modelo conjunto mediante el ajuste de los pesos de los modelos previos




Figura 51 - Proceso de diseño del modelo conjunto

En resumen, se han diseñado tres modelos para abordar la detección de anomalías en maquinaria: una CNN, una DDQN, y un modelo conjunto que combina ambos enfoques. Cada modelo tiene sus propias ventajas y características únicas, y juntos forman un enfoque completo y robusto para la detección de anomalías en maquinaria rotativa.

Resultados

Se evaluaron los modelos individuales (CNN y DDQN) y el modelo conjunto en la detección de anomalías en maquinaria rotativa. El modelo conjunto mostró la mayor precisión o “accuracy” con 94.03 %, como se muestra en la Tabla 3, ya que aprovecha las fortalezas de ambos modelos.

	CNN	DDQN	Conjunto
Accuracy	0.9391	0.8481	0.9403

Tabla 3 - Accuracy de los modelos: análisis comparativo

En términos de recall (Tabla 4), se observa una disminución en la detección de maquinaria sana (clase “healthy”), pero esto se justifica para maximizar la detección de fallos, que es crucial en este contexto.

	CNN	DDQN	Conjunto
Healthy	0.9589	0.9347	0.9558
OR fault	0.9469	0.8156	0.9514
IR fault	0.9101	0.7919	0.9122

Tabla 4 - Recall de los modelos: análisis comparativo

El modelo conjunto logra un mejor equilibrio entre la precisión y el recall, mejorando el F1-score en todas las clases de fallos. Además, las matrices de confusión, como la Figura 52, muestran que el modelo conjunto reduce los errores de clasificación para las clases de fallos, aunque también presenta algunos falsos positivos en la categorización de maquinaria sana. En resumen, el enfoque de modelo conjunto, combinando la CNN y la DDQN, resulta efectivo en la detección de anomalías en maquinaria rotativa, mejorando el rendimiento en términos de accuracy, recall y F1-score en comparación con los modelos individuales.

JOINT MODEL

Predicted Label

		Healthy	OR fault	IR fault
True Label	Healthy	3395 (32.2%)	31 (0.3%)	126 (1.2%)
	OR fault	35 (0.3%)	3425 (32.5%)	140 (1.3%)
	IR fault	192 (1.8%)	106 (1.0%)	3095 (29.4%)

Figura 52- Matriz de confusión modelo conjunto

Conclusiones

En resumen, los modelos desarrollados en este proyecto, basados en técnicas de DL y DRL, han demostrado su eficacia en la detección de anomalías en maquinaria rotativa, superando en muchos aspectos a los modelos tradicionales. Estas contribuciones son relevantes tanto desde el punto de vista académico como para las empresas que buscan mejorar la eficiencia y la seguridad de sus sistemas de monitorización de maquinaria rotativa.

Referencias

- [1] G. Qian and J. Liu, "Development of deep reinforcement learning-based fault diagnosis method," *Progress in Nuclear Energy*, vol. 152, Sep. 2022.
- [2] M. Hakim, A. A. Borhana Omran, A. Najah Ahmed, M. Al-Waily and A. Abdellatif, "A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: Taxonomy, overview, application, open challenges, weaknesses and recommendations," *Ain Shams Engineering Journal*, vol. 14, no. 4, p. 101945, 2023.
- [3] C. Lessmeier, J. K. Kimotho, D. Zimmer and W. Sextro, "Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification," *European Conference of the Prognostics and Health Management Society*, 2016.

5.3.2 | Aplicación de técnicas de Machine Learning al análisis de arranques de turbinas de gas de generación eléctrica. Trabajo de Fin de Grado

Autor: D. Daniel Vaquero Serrano

Este proyecto de investigación se centra en el proceso crítico de arranque de las turbinas de gas, con un enfoque específico en el monitoreo de la evolución de las temperaturas de los gases de escape. El objetivo principal fue desarrollar un modelo basado en técnicas de aprendizaje automático para la detección de anomalías, lo que permitiría identificar posibles situaciones de riesgo durante este proceso. Para ello, se utilizó un enfoque combinado de detección supervisada y no supervisada de anomalías, aprovechando las técnicas de DBSCAN, Mixturas de Gaussianas y regresión lineal. Este trabajo sienta unas bases para futuras investigaciones que podrían ampliar la utilidad de estos métodos con el uso de conjuntos de datos mayores.

Introducción

La transición energética del siglo XXI ha llevado a un aumento en las inversiones en energías renovables, con España alcanzando un récord histórico de producción eléctrica proveniente de estas fuentes en 2021 [1]. No obstante, el gas natural continúa siendo un actor principal en la generación de energía eléctrica debido a su menor coste, su capacidad para garantizar estabilidad en el sistema eléctrico y su adaptabilidad a la demanda [2]. Las turbinas de gas, que desempeñan un papel crucial en este proceso, son sistemas complejos cuyo funcionamiento está influenciado por múltiples variables. Un fallo en la operación de una turbina puede tener consecuencias significativas, lo que destaca la importancia de un mantenimiento y supervisión cuidadosos. Este trabajo se centrará en utilizar técnicas de aprendizaje automático para analizar datos de operación de turbinas de gas recopilados durante varios arranques, con el objetivo de caracterizar comportamientos normales y detectar anomalías.

Definición del proyecto

El objetivo principal del proyecto es caracterizar el proceso de arranque de una turbina en condiciones normales de operación y detectar posibles anomalías. Para alcanzar este objetivo, se plantearon una serie de subobjetivos como la recopilación y procesamiento de los datos de arranque de las turbinas, el diseño de una aplicación web de visualización de datos, y la aplicación de técnicas de aprendizaje automático para la caracterización de los patrones normales de las temperaturas de los gases de escape.

Descripción del modelo

Se utilizó un enfoque combinado de detección supervisada y no supervisada de anomalías para manejar la escasez de ejemplos de anomalías. Las técnicas de DBSCAN y Mixturas de Gaussianas (Figura 53) se aplicaron para la detección no supervisada, aprovechando su capacidad para identificar anomalías en regiones de baja densidad. Además, se empleó un enfoque supervisado basado en regresión, donde las variables altamente correlacionadas se usan como características para predecir los valores de una variable objetivo y se definen como anomalías aquellos puntos que tienen un residuo de predicción grande.



Figura 53 Forma esquemática de las regiones de decisión

A continuación, se diseñó un mecanismo de detección de anomalías de arranques basado en las técnicas antes mencionadas, mediante el que se solapan las regiones de decisión de cada uno de los métodos y se definen cuatro nuevas subregiones de decisión en función del consenso de los métodos.

- Sección azul (zona A): 3 votos.
- Sección morada (zona B): 2 votos.
- Sección roja (zona C): 1 voto.
- Sección exterior (zona D): 0 votos.

En la Figura 54 se observa como resultarían las secciones de decisión tras el solapamiento de las regiones de la Ilustración A.1.




Figura 54 Forma esquemática de la superposición de las regiones de decisión

Antes de la aplicación conjunta de los métodos, se define el siguiente umbral de decisión:

- Puntos normales: zonas A y B, pues implica consenso de normalidad entre al menos 2 clasificadores.
- Anomalías: zonas C y D, pues no hay consenso de normalidad.

Resultados

Finalmente, se definió una puntuación para medir el nivel de anomalías combinado de aplicar la metodología a diferentes pares de variables.

$$\text{Puntuación} = \sum \left(\frac{\text{número anomalías}}{\text{número muestras intervalo}} \right)^2$$

De esta manera, se obtiene la relación de arranques mostrada en la Tabla 5.

TG	Fecha	Ciclo	Revisión	Momento	Puntuación
TG4	2021/08/09T16	abierto	PC	P.S.	5.22
TG4	2021/02/27T17	abierto	FH	T.R.	1.36
TG6	2022/08/17T07	cerrado	--	rnd.	1.14
TG6	2022/01/12T11	abierto	--	rnd.	1.08
TG6	2021/09/14T06	abierto	IC	A.R.	1.02
...					
TG6	2021/09/29T16	abierto	IC	T.R.	0.00
TG6	2020/02/23T09	cerrado	PC	A.R.	0.00
TG5	2020/08/04T07	cerrado	PC	A.R.	0.00
TG5	2020/08/11T05	abierto	--	rnd.	0.00
TG5	2020/08/07T09	cerrado	IC	P.S.	0

Tabla 5 Relación de arranques por mayor nivel de anomalías

Por último, se tomó un arranque con una alta puntuación de anomalías y un arranque con una baja puntuación de anomalías como arranques modelo para una comparación mediante la distribución de las temperaturas medidas por los termopares en los 21 puntos diferentes de la circunferencia de la turbina.




Figura 55 Evolución de las temperaturas en arranque sin anomalías




Figura 56 Evolución de las temperaturas en arranque anómalo

En la Figura 55, se observa cómo las temperaturas del arranque normal modelo evolucionan creciendo de manera monótona y suave, tanto en función del tiempo como de la potencia. Además, se observa una excelente estabilidad en la evolución del punto más frío y del punto más caliente de la turbina. En contraste, en la Figura 56 se observa un comportamiento bastante diferente del arranque anómalo modelo. En lugar de un crecimiento monótono y suave de las temperaturas de arranque, se presentan fluctuaciones tanto en función del tiempo como de la potencia. La falta de estabilidad en la evolución de los puntos de frío y calor máximo de la turbina también sugiere posibles problemas de distribución de calor dentro del sistema.

Conclusiones

Los objetivos propuestos al inicio del proyecto de investigación se cumplieron efectivamente, demostrando el potencial de las técnicas de aprendizaje automático para la detección de anomalías en el proceso de arranque de las turbinas de gas. Sin embargo, se reconoce que este trabajo es solo un punto de partida y que futuras investigaciones podrían beneficiarse de una mayor cantidad y homogeneidad de datos, así como de la exploración de líneas de investigación adicionales, como la integración de estas técnicas con sistemas de control en tiempo real.

Referencias

- [1] Red Eléctrica de España, «El Sistema Eléctrico Español: Sistema eléctrico 2021», Informe del sistema eléctrico, junio 2022. https://www.sistemaelectrico-ree.es/sites/default/files/2022-08/InformeSistemaElectrico_2021.pdf
- [2] J. Woollacott, «A bridge too far? The role of natural gas electricity generation in US climate policy», Energy Policy, vol. 147, p.118, 2020. <https://doi.org/10.1016/j.enpol.2020.111867>

5.3.3 | Aplicación de técnicas de Inteligencia Artificial al diagnóstico y mantenimiento de centrales eléctricas. Trabajo de Fin de Máster

Autor: D. Fernando del Pino Osborne

Introducción

Este Trabajo Fin de Máster se centra en la utilización de aprendizaje automático e inteligencia artificial para el diagnóstico y mantenimiento de una bomba de agua de alimentación de la turbina de vapor de una central de ciclo combinado. El proyecto abarca la caracterización y modelización del comportamiento operativo normal de la bomba, así como la detección preventiva de anomalías y posibles fallos, con el objetivo final de optimizar la estrategia de mantenimiento. La motivación de este trabajo radica en la necesidad de mejorar la eficiencia y fiabilidad en las operaciones de mantenimiento de centrales eléctricas de ciclo combinado, dado su papel crucial en la producción de energía a gran escala y la estabilidad del suministro eléctrico. El uso ineficaz del mantenimiento puede resultar en fallos imprevistos, costosas interrupciones y riesgos de seguridad. Las tecnologías de inteligencia artificial, aprendizaje automático y análisis predictivo prometen transformar el mantenimiento de reactivo a proactivo y prescriptivo, reduciendo así los tiempos de inactividad y aumentando la eficiencia operativa.

Objetivos

Este trabajo se centra en varios objetivos clave relacionados con la bomba de agua de alimentación en el ciclo agua-vapor de una central de ciclo combinado. En primer lugar, se realizará un análisis exhaustivo de los posibles modos de fallo de la bomba de agua de alimentación. A continuación, se desarrollarán modelos de funcionamiento normal de estas bombas basados en datos reales, lo que permitirá una comprensión más precisa de su comportamiento en condiciones óptimas. Finalmente, se buscará detectar las anomalías presentes a lo largo de la serie histórica de datos utilizando los modelos de funcionamiento normal como referencia.

Estado del Arte

La detección y análisis de fallos es un campo amplio, objeto de estudio desde hace muchos años. A continuación se describe su estado actual, analizando las estrategias de mantenimiento, los métodos FDI clásicos, los algoritmos de ML e IA de diagnóstico de fallos y los principales retos relacionados con la detección de fallos.

Se distinguen distintas estrategias de mantenimiento. El mantenimiento correctivo se basa en la reparación o reemplazo de partes únicamente cuando fallan, lo cual es simple pero costoso debido a las reparaciones no planificadas. El mantenimiento preventivo, por otro lado, se basa en inspecciones regulares programadas que reducen los fallos inesperados, aunque pueden resultar en reemplazos innecesarios. El mantenimiento basado en condición utiliza sensores para monitorear continuamente el estado del equipo y realiza mantenimiento solo cuando es necesario. El mantenimiento predictivo combina sensores y análisis de datos para prever fallos y programar el mantenimiento dinámicamente. Finalmente, el mantenimiento prescriptivo no solo predice fallos, sino que también sugiere acciones correctivas. [1]

Los métodos clásicos de detección y aislamiento de fallos (FDI) incluyen las ecuaciones de paridad, los observadores diagnósticos y el filtrado de Kalman, todos basados en la generación de residuos a partir

de modelos matemáticos que representan el comportamiento esperado del sistema. Las ecuaciones de paridad comparan las salidas reales con las predichas, los observadores diagnósticos estiman el estado del sistema y comparan salidas observadas con estimadas, y el filtro de Kalman, conocido por su robustez, facilita pruebas estadísticas al generar residuos no correlacionados. Estos métodos han sentando las bases para técnicas más avanzadas y robustas. [2]


En los últimos años se han desarrollado técnicas más modernas basadas en algoritmos de ML e IA. El algoritmo k-Nearest Neighbour (k-NN) es simple de implementar y efectivo, aunque requiere gran cantidad de memoria y computación. El algoritmo Naive Bayes es robusto frente a valores perdidos y eficiente en almacenamiento, pero se basa en suposiciones de independencia previas fuertes. Support Vector Machine (SVM) ofrece buena aproximación de funciones complejas, aunque su eficiencia disminuye con grandes volúmenes de datos. Las Artificial Neural Networks (ANN) son buenas para aproximar funciones no lineales complejas, pero tienen muchos parámetros y son susceptibles al sobreajuste. Finalmente, el Deep Learning permite aprender características automáticamente y manejar estructuras complejas de datos, aunque necesita grandes volúmenes de datos y un entrenamiento prolongado. [3]

Los principales retos incluyen errores y ruido en los datos, ya que los sensores pueden generar datos erróneos. La falta de generalización es otro desafío, ya que los modelos de predicción suelen estar diseñados para condiciones específicas, lo que limita su aplicabilidad en otros contextos. Además, la recolección y procesamiento eficaz de datos es crucial, considerando la diversidad y dispersión geográfica de los activos de producción, donde tecnologías como el IoT y el Edge Computing pueden ofrecer soluciones. [1]


Modos de Fallo

La base de los modelos de comportamiento normal es un examen exhaustivo de los posibles modos de fallo asociados a la bomba, es decir, las diferentes formas en que este componente puede fallar. A continuación se muestra un esquema de los principales modos de fallo de una bomba centrífuga, agrupados en tres categorías distintas de fallos. [4]


Modos de fallos hidráulicos comunes y variables relacionadas



Modos de fallos mecánicos comunes y variables relacionadas



Modos de fallos eléctricos comunes y variables relacionadas



Proceso de Modelado

Este apartado describe los pasos seguidos para el preprocesamiento de datos, obtención y validación del modelo, y la evaluación del riesgo de fallo.

- **Preprocesamiento y Filtrado de Datos**

Primero, se procede al aislamiento del periodo de explotación. Para ello, se selecciona el intervalo de tiempo en el que la bomba opera a un ritmo constante, excluyendo datos de arranque, parada y estados transitorios, con el objetivo de evitar introducir ruido en el análisis.

A continuación, se realiza la identificación de un periodo de entrenamiento válido. Este subperiodo se caracteriza por la ausencia de eventos de mantenimiento y averías importantes. Los datos se dividen en entrenamiento (80 %), validación (20 % del entrenamiento) y prueba (20 %).

Se procede luego a la creación de variables virtuales y normalización. Para ello, se generan variables derivadas como la intensidad de fase media del motor y el estado operativo de la potencia de vapor. Posteriormente, se normalizan las variables utilizando el conjunto de entrenamiento, con el fin de mejorar el rendimiento del modelo.

- ***Obtención del Modelo y Validación***

Esta fase se inicia con la selección de características objetivo y de entrada. La variable seleccionada como objetivo es aquella cuyo comportamiento potencialmente anómalo sirve como indicador de la ocurrencia del fallo. Las variables de entrada son aquellas que ayudarán a modelar la variable de salida y tienen relación con ella.

Luego, se realiza la selección y entrenamiento del modelo. Se opta por una red neuronal perceptrón multicapa (MLP) debido a su capacidad para captar relaciones no lineales complejas. Se optimizan los siguientes hiperparámetros: número de capas, neuronas, tasa de aprendizaje, tamaño del batch y tasa de dropout. Seguidamente, se procede con la validación del modelo. Se verifica que la distribución de los residuos sea normal y se comprueba que el modelo no se haya sobreajustado.

Finalmente, se evalúa la importancia de las variables de entrada utilizando el algoritmo de gradientes integrados, lo que permite determinar la importancia relativa de cada variable de entrada.

- ***Evaluación del Riesgo de Fallo***

Para identificar fallos potenciales, se ajusta una mezcla gaussiana a los residuos del modelo y se calculan los intervalos de confianza del 99 % de comportamiento normal.

Se considera anómalo cualquier residuo fuera de estos intervalos. La suma acumulada de estas desviaciones en el tiempo se representa en una curva de riesgo, que ayuda a detectar anomalías antes de que se conviertan en fallos críticos.

- ***Modelos Obtenidos***

Se han desarrollado siete modelos predictivos con el objetivo de detectar modos de fallo específicos en una bomba de alimentación. Cada modelo está diseñado para monitorear una variable particular que puede indicar un problema potencial en el sistema.



Resumen de Modelos Identificados y Modos de Fallo

Modelos	Modo de fallo	Variables de entrada
Caudal de descarga	Fugas	Intensidad de fase media, presión de aspiración, potencia de la turbina de vapor
Presión de descarga	Pulsaciones de presión	Caudal de descarga, presión de aspiración, potencia de la turbina de vapor, configuración de potencia de vapor
Velocidad de vibración del cojinete de empuje	Desgaste del cojinete de empuje	Desplazamiento de los cojinetes radiales, intensidad media de fase,, configuración de potencia de vapor
Temperatura del cojinete de empuje	Desgaste del cojinete de empuje	Desplazamiento de los cojinetes radiales, intensidad media de fase, potencia de la turbina de vapor
Temperatura de la fase R del motor	Problemas de cortocircuito	Caudal de descarga, presión de aspiración, intensidad de la fase R del motor potencia de la turbina de gas, potencia de la turbina de vapor
Intensidad de la fase R del motor	Sobrecarga del motor	Presión de aspiración, potencia de la turbina de gas, potencia de la turbina de vapor, configuración de potencia de vapor
Temperatura de descarga	Cavitación	Presión de aspiración, intensidad media de fase del motor, potencia de la turbina de vapor, configuración de potencia de vapor

Conclusión y futuros desarrollos

Este Trabajo Fin de Máster ha demostrado la viabilidad y eficacia de aplicar técnicas de inteligencia artificial y aprendizaje automático en el diagnóstico y mantenimiento preventivo de activos críticos en centrales eléctricas de ciclo combinado, específicamente en bombas de agua de alimentación. Mediante el análisis exhaustivo de modos de fallo y el desarrollo de modelos predictivos basados en redes neuronales, se ha logrado detectar anomalías tempranas, optimizando así la estrategia de mantenimiento y reduciendo costes operativos. Los resultados validan la capacidad de estos modelos para mejorar la fiabilidad y eficiencia de la planta, aunque se reconocen desafíos como la calidad de los datos y la generalización de los modelos. Futuros desarrollos incluyen la ampliación de esta metodología a otros componentes, mejoras en los modelos actuales, integración en sistemas de monitoreo en tiempo real, evaluación económica y automatización de la selección de variables, sentando las bases para avances tecnológicos en la industria energética.

Referencias

- [1] P. Nunes, J. Santos y E. Rocha, «Challenges in predictive maintenance—A review, » CIRP Journal of Manufacturing Science and Technology, vol. 40, págs. 53-67, 2023.
- [2] J. Gertler, «Analytical redundancy methods in fault detection and isolation survey and synthesis,» IFAC Proceedings Volumes, vol. 24, n.o 6, págs. 9-21, 1991.
- [3] R. Liu, B. Yang, E. Zio y X. Chen, «Artificial intelligence for fault diagnosis of rotating machinery: A review,» Mechanical Systems and Signal Processing, vol. 108, págs. 33-47, 2018.
- [4] K. McKee, G. Forbes, M. I. Mazhar, R. Entwistle e I. Howard, «A review of major centrifugal pump failure modes with application to the water supply and sewerage industries,» en ICOMS Asset Management Conference Proceedings, Asset Management Council, 2011.

5.3.4 | Caracterización del comportamiento de bombas de agua de circulación mediante técnicas de Machine Learning. Trabajo de Fin de Máster

Autora: D.^a Marta Casero Martín

En este proyecto se ha caracterizado el comportamiento de dos bombas de agua de circulación (BAC1 y BAC2) de una central de generación eléctrica de ciclo combinado. Se ha desarrollado un modelo que evalúa el comportamiento de las bombas para así obtener grupos de funcionamiento similar por periodos de tiempo. Además, se ha comparado el funcionamiento de las bombas con tareas de mantenimiento preventivo y correctivo realizadas en ellas.

Introducción

Se ha podido ver que existen varios estudios en los que se ha trabajado en temas de detección de anomalías dentro de distintos sectores, como el sector de oficinas [1] y otros sectores industriales [2]. Además, se ha observado que ninguno de los trabajos revisados tiene en cuenta en su análisis tareas de mantenimiento realizadas en sus instalaciones.

Es por ello, que este trabajo persigue analizar en detalle el funcionamiento de dos bombas de agua de una central de generación eléctrica. Se ha realizado un análisis preliminar del comportamiento de las bombas a través de la elaboración de sus curvas características semanales y así obtener los coeficientes de dichas curvas.

Además, se ha desarrollado un modelo basado en mapas autoorganizados (SOM) [3] para así obtener grupos de rendimiento por periodos de tiempo. Se ha analizado la evolución en el tiempo de estos grupos de rendimiento comparándolo a su vez con tareas de mantenimiento preventivo y correctivo.

Para la elaboración de este proyecto se ha usado datos relativos al funcionamiento de las dos bombas de agua como valores de presión, caudal e intensidad media.

Definición del proyecto

Para desarrollar el modelo basado en SOM que caracteriza el comportamiento de dos bombas de agua se ha seguido una serie de objetivos que se recogen en el flujo de trabajo de la Figura 57. En primer lugar, se ha realizado un análisis preliminar del comportamiento de las bombas a través de las curvas características de caudal-presión. Esto ha permitido tener una visión general de los datos y poder filtrar aquellos datos atípicos y que pueden distorsionar el análisis posterior que se va a realizar.

Adicionalmente, se ha construido la curva característica semanal para cada bomba. Para cada bomba, se ha determinado el grado óptimo del polinomio (curva característica) durante la primera semana y se ha utilizado ese mismo grado para ajustar las curvas de las semanas siguientes. Al mantener el mismo grado de polinomio, se puede identificar si realmente ha habido variaciones entre semanas.

Después, se ha pasado a la elaboración del modelo basado en mapas autoorganizados (SOM) que nos va a permitir analizar el comportamiento de las bombas por periodos de tiempo. Este modelo incluye dos métodos para evaluar el comportamiento de las bombas, cuya diferencia cae en las entradas del modelo. El primer método tiene como entrada los valores de presión, caudal e intensidad media de la bomba. Mientras que el segundo método también incluye los coeficientes de las curvas características. El modelo agrupa los datos de entrada en distintas neuronas y calcula el rendimiento medio para cada una de ellas.

Con este modelo desarrollado, se ha pasado al etiquetado de los pesos de las neuronas del SOM en distintos grupos de rendimiento. Además, se ha mostrado la evolución temporal del porcentaje de neuronas correspondientes a cada grupo de rendimiento. De esta manera, se ha podido analizar el comportamiento de las bombas a lo largo del periodo estudiado, identificando los momentos en los que las bombas han funcionado mejor o peor.

Finalmente, se han utilizado datos de las tareas de mantenimiento realizadas a las bombas para comparar sus efectos con los resultados obtenidos del modelo desarrollado con mapas autoorganizados. Esto ha permitido evaluar cómo las tareas de mantenimiento y los fallos ocurridos han afectado el comportamiento de las bombas de agua.




Figura 57. Flujo de trabajo.

Descripción del modelo/sistema/herramienta

Se ha desarrollado un modelo basado en mapas autoorganizados (SOM) para poder evaluar y mostrar el comportamiento de las bombas a lo largo del tiempo. Este modelo tiene como objetivo obtener grupos de rendimiento por periodos de tiempo.

El modelo emplea dos métodos diferentes, dependiendo de los datos de entrada. El primer método utiliza datos de potencia, caudal e intensidad media. El segundo método incluye, además, los coeficientes de las curvas características.

A la salida del modelo, se obtiene una representación del funcionamiento de las bombas a través de su eficiencia. Este modelo evalúa tanto periodos anuales como mensuales. Es importante señalar que siempre se define un periodo de referencia, el cual permite medir los cambios en el comportamiento de la bomba respecto a dicho periodo.

En la Figura 58, se muestra la salida del modelo con los datos de enero de 2020 y utilizando el modelo que no considera los coeficientes de las curvas características. Se puede ver que para cada neurona del modelo SOM se indica el porcentaje de datos que caen en ella y su eficiencia media.




Figura 58. Modelo SOM datos BAC1 periodo mensual (2020, 1) sin coeficientes.

Resultados

A partir del modelo SOM desarrollado se ha etiquetado las neuronas del modelo en distintos grupos de rendimiento. Se ha avanzado al estudio de estos grupos de rendimiento a lo largo del tiempo. Además, se ha comparado todo esto con tareas de mantenimiento correctivo y preventivo. La Figura 59 muestra la evolución de los distintos grupos de rendimiento para la BAC1 utilizando el modelo SOM que no incluye los coeficientes de las curvas características. Se puede ver como ciertas tareas preventivas como la de octubre de 2022 tiene un gran impacto positivo en el rendimiento de la bomba. Sin embargo, existen otras tareas preventivas como la de octubre 2020 que no han sido igual de efectivas y no ha mejorado el rendimiento de la bomba.

Evolución del porcentaje de etiquetas por mes para BAC1




Figura 59. Evolución temporal de los grupos de rendimiento relativos a la BAC1 con modelo sin coeficientes.

Conclusiones

Con este proyecto, se ha logrado desarrollar un modelo que permite mostrar y evaluar el funcionamiento de dos bombas de agua, identificando distintos grupos de rendimiento a lo largo del tiempo. Además, se ha estudiado cómo las diferentes tareas de mantenimiento preventivo y correctivo han afectado el comportamiento de las bombas. Esto proporciona una herramienta valiosa para optimizar el rendimiento y la eficiencia de las bombas, así como para planificar estrategias de mantenimiento más efectivas.

Referencias

[1] J.-S. a. S. T. A. Chou, «Real-time detection of anomalous power consumption,» ScienceDirect, vol. 33, pp. 400-411, Mayo 2014.

[2] Y. Choi, H. Lim, H. Choi y I.-J. Kim, «GAN-based Anomaly Detection and Localization of Multivariate Time Series Data for Power Plant,» IEEE Xplore, pp. 71-74, 2020.

[3] «Medium,» 27 Noviembre 2023. [En línea]. Available: <https://medium.com/@alejandravz/agrupamiento-de-im%C3%A1genes-con-mapas-autoorganizados-bf05ca8136f2>

5.3.5 | Redes neuronales adversarias en el mundo IIoT. Uso de sus resultados en la estimación de ciclo de vida. Trabajo de Fin de Máster

Autor: D. Javier Álvarez Martínez

Introducción

El mantenimiento predictivo es una estrategia avanzada que utiliza el monitoreo continuo y el análisis de datos en tiempo real para anticipar y prevenir fallos en sistemas y componentes críticos. A diferencia del mantenimiento reactivo o preventivo tradicional, el mantenimiento predictivo se apoya en datos para identificar patrones y prever problemas antes de que ocurran, lo que permite una planificación y ejecución del mantenimiento más eficiente. En el contexto del "Internet Industrial de las Cosas" (IIoT), esta estrategia se fortalece con la incorporación de tecnologías avanzadas como el Machine Learning (ML) y el Deep Learning (DL).

Este proyecto se enfoca en la aplicación de Redes Neuronales Generativas Adversarias (GANs) [1] para generar datos sintéticos, es decir, aplicación de técnicas de Data Augmentation [2] que mejoren los modelos predictivos del tiempo de vida útil (RUL) de componentes críticos, como los motores de avión. La falta de datos de fallos reales es un desafío importante en el entrenamiento de modelos predictivos, y las GANs ofrecen una solución innovadora al crear datos sintéticos realistas que enriquecen los conjuntos de datos disponibles.

El proyecto se centra la generación de datos sintéticos de valores generados por sensores en el motor de avión como el que se muestra en la Figura 60 y en el cálculo del tiempo de vida útil de estos motores.




Figura 60. Componentes del motor turbofan de un avión.

Objetivos del proyecto

Los objetivos del proyecto son los siguientes:

- Estudio de la Redes Neuronales Adversarias y su aplicación en el mundo de la generación de datos sintéticos.
- ETL (Extracción, Transformación y Carga) de un dataset sin procesar, selección de variables, modificación de estas y la transformación en un conjunto de datos preparado para ser usado en modelos de Machine Learning.
- Elaboración y optimización de una GAN adaptada a los datos tratados previamente y con la capacidad de realizar Data Augmentation.
- Generación de datos sintéticos con la misma distribución o lo más similar posible a la de los datos originales.
- Elaboración de modelos de regresión basados en Ensembles, concretamente árboles y modelos de boosting para la predicción del RUL. Además, elaboración de modelo LSTM para el mismo propósito.
- Comparación de modelos entre ellos y comparación de modelos utilizando Data Augmentation frente a los mismos modelos sin usar generación de datos sintéticos.

Descripción del sistema

El esquema del proyecto desarrollado se muestra en la siguiente Figura 61:




Figura 61. Esquema del proyecto desarrollado.

El sistema desarrollado comienza con una fase de ETL (Extracción, Transformación y Carga) donde se preparan los datos del dataset CMAPSS de la NASA. Estos datos se limpian y transforman para asegurar que estén en un formato adecuado para el análisis y el modelado. Una vez preparados, se implementa una red generativa adversaria (GAN), compuesta por un generador que crea datos sintéticos y un discriminador que evalúa su autenticidad. La GAN se optimiza mediante la búsqueda de hiperparámetros para mejorar la calidad de los datos sintéticos generados. La creación de esta red se ha basado en el paper "Generative adversarial networks based remaining useful life estimation for IIoT". [3]

Con los datos sintéticos generados, se entrenan modelos de predicción del tiempo de vida útil (RUL) utilizando tanto datos reales como sintéticos. Estos modelos incluyen redes neuronales LSTM y otros algoritmos de regresión basados en Ensembles. La inclusión de datos sintéticos amplía el conjunto de datos disponible, mejorando la capacidad de los modelos para capturar patrones y tendencias asociados con el desgaste y fallos de los componentes críticos.

Finalmente, se realizarán los modelos de predicción entrenados sin datos sintéticos para posteriormente en los resultados comparar si esto tiene resultados positivos en el proyecto y utilidad en el mantenimiento predictivo.

Resultados

Los resultados que se tratan en este proyecto son los siguientes: precisión de la GAN y generación de datos sintéticos; resultados y comparación de modelos usando Data Augmentation; resultados y comparación de modelos usando y sin usar Data Augmentation.

En primer lugar, se ha evaluado la precisión de la GAN tras haberla entrenado.





Figura 62. Losses over epochs para RUL 0.

Como se puede apreciar en la Figura 62, la curva de pérdidas para las 400 épocas definidas es razonable. Se observa como el valor medio de loss es razonablemente bajo por lo que es un valor que se ha considerado óptimo para este proyecto y por ello hemos decidido como aceptable.

Otro punto importante en la generación de datos sintéticos era la capacidad de generar datos sintéticos que siguieran la muestra de datos original, de esta manera se consigue una muestra con mayor número de datos, pero con una distribución sensata y parecida a los datos de los que se dispone.

En las siguientes gráficas (Figura 62) se muestran las distribuciones de los datos originales y en la de al lado los datos totales incluyendo el dataset original y la combinación con los datos sintéticos. Como se puede ver en las imágenes la muestra generada con mayor número de datos es prácticamente idéntica a la original, que era lo deseado.

Distribución de datos originales



Distribución de datos combinados




Figura 63. Distribución de datos originales (arriba) y combinados (abajo).

Por último, se muestra una tabla comparativa entre los modelos para los que se ha entrenado con el dataset combinado con datos sintéticos y datos originales y además el conjunto de datos de train y test es el mismo para todos los modelos.

Tabla de Resultados 1. RMSE en Train y Test para los diferentes modelos

Algoritmo	RSME Train	RMSE Test
Random Forest	7,39	1,47
Gradient Boosting	22,53	10,78
LightGBM	18,54	2,63
XGBoost	15,47	3,1
LSTM	24,68	12,84

Como se puede apreciar, Random Forest es el modelo más eficaz para la predicción del RUL en este caso específico. Su rendimiento superior en los datos de prueba hace que sea la opción más precisa y confiable. Aunque modelos como LightGBM y XGBoost también ofrecen buenos resultados, Random Forest demuestra una capacidad mayor para predecir con alta precisión, lo que lo convierte en la mejor elección para esta tarea y estos datos. Además, es reseñable como todos los modelos son capaces de generalizar a datos no vistos.

Por último, se muestra una tabla comparativa entre los diferentes modelos usando Data Augmentation frente a los mismos datos sin haber usado la generación de datos sintéticos.

Tabla de Resultados 2. Comparativa de resultados para los diferentes modelos usando DA vs no hacerlo

Algoritmo	RSME Train	RMSE Test
Random Forest con DA	7,39	1,47
Random Forest sin DA	12,34	44,06
Gradient Boosting con DA	22,53	10,78
Gradient Boosting sin DA	31,78	43,81
LightGBM con DA	18,54	2,63
Gradient Boosting sin DA	27,49	44,38
XGBoost con DA	15,47	3,1
XGBoost sin DA	19,11	45,84
LSTM con DA	24,68	12,84
LSTM sin DA	16,31	19,1

Las comparaciones entre los modelos entrenados con y sin Data Augmentation revelaron que los modelos que incluían datos sintéticos presentaron un rendimiento superior siendo capaces de evitar el sobreajuste de los datos de entrenamiento. También cabe destacar como el modelo LSTM funciona mejor debido a su uso nativo para la predicción en series temporales.

Bibliografía

- [1] Nadal Comparini. 2022. Redes Neuronales Generativas Adversarias. Data, Machine Learning, Visualization. <https://blog.damavis.com/redes-neuronales-generativas-adversarias-gans/>
- [2] Ali Awan, A. Noviembre 2022. A complete guide to Data Augmentation. Datacamp. <https://www.datacamp.com/tutorial/complete-guide-data-augmentation>
- [3] Behera, S y Misra, R. 2021. Generative adversarial networks based remaining useful life estimation for IIoT. Computers and Electrical engineering. ELSEVIER

5.3.6 | Aplicación de técnicas de Machine Learning al diagnóstico de la combustión de una turbina de gas. Trabajo de Fin de Máster

Autora: D.^a María del Carmen Rubiales Mena

 este trabajo se describe un método basado en la combinación de varias técnicas de aprendizaje automático que trabajan en conjunto con el objetivo de monitorizar continuamente la combustión de una turbina de gas perteneciente a un ciclo combinado, mediante la observación de las mediciones de temperatura de los gases de escape disponibles y las variables de las condiciones de operación con Técnicas de Aprendizaje Automático. El objetivo de esta monitorización es la detección automática de anomalías lo antes posible en las cámaras de combustión y de los posibles fallos en los termopares de medición en la turbina de gas. Se estudiaron cuatro turbinas de gas, cada una equipada con veintiún termopares ubicados en la salida de los gases de escape de las distintas turbinas para medir la temperatura en cada cámara de combustión.

El método de detección de anomalías desarrollado se basa en un conjunto que combina modelos que caracterizan el comportamiento normal esperado sin anomalías, en particular, se han aplicado redes neuronales y análisis de componentes principales (PCA). Estos modelos se utilizan para comparar el rendimiento actual de la turbina de gas con el rendimiento pasado en períodos de referencia conocidos como condiciones normales de funcionamiento. Si el comportamiento observado es diferente al esperado, se analiza para encontrar la causa de esta anomalía que podría estar enfocada en un termopar específico o en algunas cámaras de combustión. Esto es muy útil para planificar el mantenimiento y para ahorrar tiempo al eliminar el problema observado. En este trabajo se describen los métodos desarrollados y casos reales de aplicación. Los resultados obtenidos han validado la estrategia propuesta.

Se puede ver el trabajo completo en el apartado 5.1 de esta Memoria (pág 15).

5.3.7 | Aplicación de técnicas de Machine Learning para el diagnóstico del comportamiento de bombas de agua de circulación de una central de generación eléctrica. Trabajo de Fin de Grado

Autor: D.ª Inés Rodríguez Aguilar

Este proyecto presenta el desarrollo de un sistema de diagnóstico predictivo aplicado a las bombas de circulación de agua en una central de ciclo combinado, basado en aprendizaje por refuerzo (TD3). Se emplean datos reales (2020–2023) para entrenar agentes que predicen valores de temperatura, presión y desplazamiento, y se traduce el error de predicción en curvas de estrés acumulado. Con ello, se permite detectar anomalías con antelación y optimizar las tareas de mantenimiento, lo que resulta en una reducción de los costes operativos.

Introducción

La disponibilidad y fiabilidad de las bombas de circulación de agua son esenciales para el funcionamiento continuo de una central de ciclo combinado, ya que garantizan el retorno del condensado a las calderas y mantienen la estabilidad del proceso térmico. Cuando estas bombas fallan sin aviso, pueden desencadenarse paradas imprevistas que provocan costes elevados, retrasos en la generación y riesgos en el resto de los equipos. Los métodos convencionales basados en límites estáticos o inspecciones programadas suelen generar falsas alarmas o no detectar degradaciones progresivas.

Frente a estas limitaciones, este trabajo explora un enfoque basado en inteligencia artificial, donde un gemelo digital integrado con un agente de aprendizaje por refuerzo aprende el comportamiento normal de la bomba a partir de datos reales. En lugar de necesitar etiquetar los fallos manualmente, el agente se entrena para predecir la señal siguiente y reporta anomalías cuando su predicción difiere de la medida real. De este modo, se consigue una monitorización adaptativa capaz de anticipar modos de fallo antes de que se conviertan en incidentes críticos.

Objetivos del proyecto

El propósito principal de este proyecto es construir un sistema capaz de anticipar modos de fallo en las bombas de circulación sin depender de datos etiquetados manualmente ni de inspecciones constantes. Para ello, se dispone de registros históricos de la planta correspondientes al periodo 2020–2023. En una fase inicial de preprocesado, se descartan los tramos en los que las bombas arranquen o se detengan y se limpian los datos eliminando valores anómalos y normalizando las señales para que todas las variables compartan una escala común.

Una vez preparados los datos, se definen entornos de simulación en los que el agente TD3 toma como entrada el conjunto de mediciones disponibles en cada instante y genera una predicción sobre el valor siguiente. Cada vez que su predicción difiere del valor real, se añade un incremento al indicador llamado estrés. Al acumular todos estos incrementos, se obtiene la curva de estrés acumulado.

Cuando esta curva muestra un comportamiento ascendente prolongado, se interpreta como una señal de que el sistema comienza a desviarse de su funcionamiento normal. De esta forma, se obtiene un mecanismo de alerta temprana que permite programar tareas de mantenimiento antes de que el fallo se materialice.

Descripción del sistema

El modelo está basado en el algoritmo TD3, una técnica de aprendizaje por refuerzo que ha demostrado funcionar muy bien en entornos continuos. En este caso, el entorno está formado por secuencias temporales de variables como potencia, temperatura y presión. Se ha optado por una arquitectura simple, con un modelo por cada señal relevante, para facilitar la interpretación.

El entrenamiento se realiza exclusivamente con datos del año 2020. A partir de ahí, los modelos se aplican a los años posteriores (2021–2023) para evaluar su capacidad de generalización. En cada paso, el agente recibe un conjunto de observaciones y devuelve una predicción, que se compara con el valor real para calcular el error. Este error se normaliza y se compara con un umbral estadístico definido por $\pm 3\sigma$ (tres veces la desviación estándar). Solo cuando la desviación supera ese límite, se interpreta como señal de estrés y se acumula en la curva correspondiente.

El proceso general seguido por el sistema se resume en la Figura 64, donde se representa cómo las señales de planta se transforman en predicciones, errores y finalmente en la curva de riesgo.




Figura 64 - Esquema conceptual del sistema de diagnóstico basado en aprendizaje por refuerzo

Resultados

A lo largo del proyecto se han desarrollado seis modos de fallo diferentes, cada uno centrado en un comportamiento anómalo concreto de una bomba. Para cada modo se han entrenado uno o varios modelos independientes, y en total se han evaluado diez modelos. En todos los casos, las curvas de estrés acumulado muestran una evolución coherente con la aparición y desarrollo de los fallos.

En los modos donde las señales responden de forma más clara ante una desviación (por ejemplo, un aumento de temperatura), los modelos detectan el fallo de forma rápida y consistente. En otros casos, donde los cambios son más graduales o sutiles, el sistema es capaz de acumular pequeñas desviaciones hasta generar una alerta progresiva.

Además, se ha observado que al combinar varios modelos que analizan distintas señales del mismo modo de fallo, se obtiene una visión más completa de lo que está ocurriendo. La Figura 65 muestra un ejemplo de cómo los distintos modelos acumulan estrés en momentos similares, pero con diferentes intensidades, reforzando la idea de que el sistema es capaz de integrar distintas perspectivas del mismo problema.

Además, se ha observado que al combinar varios modelos que analizan distintas señales del mismo modo de fallo, se obtiene una visión más completa de lo que está ocurriendo. La Ilustración 2 muestra un ejemplo de cómo los distintos modelos acumulan estrés en momentos similares, pero con diferentes intensidades, reforzando la idea de que el sistema es capaz de integrar distintas perspectivas del mismo problema.




Figura 65 - Estrés acumulado total por modelo del modo del fallo “Desalineación del eje” en el periodo 2021–2023

Conclusiones

El sistema propuesto ha demostrado ser capaz de detectar con antelación comportamientos anómalos en señales clave de las bombas de circulación, usando únicamente datos históricos sin etiquetas. A lo largo del proyecto se ha comprobado que el enfoque basado en aprendizaje por refuerzo no solo es viable, sino que resulta eficaz incluso en condiciones reales de planta, donde los datos presentan ruido, interrupciones y otras complicaciones habituales.

Una de las principales aportaciones del proyecto ha sido validar que este tipo de modelos pueden adaptarse a fallos muy distintos, y que los indicadores de estrés acumulado ofrecen una forma intuitiva de seguir su evolución. Además, se ha conseguido que el sistema sea fácil de integrar en entornos reales, al apoyarse en señales que ya se recogen de forma rutinaria.

Se han cumplido los objetivos marcados: desarrollar un sistema flexible, validado con datos reales, y que ofrezca valor en la toma de decisiones de mantenimiento. El resultado es un sistema que no pretende sustituir al criterio experto, pero sí aportar una herramienta adicional para anticiparse a los fallos y actuar antes de que se materialicen.

Bibliografía

- [1] Sanz-Bobi, M. A., et al. “Anomaly Detection of a Cooling Water Pump of a Power Plant Based on its Virtual Digital Twin Constructed with Deep Learning Techniques.” PHM Society European Conference, 2024.
- [2] Stable Baselines3 Documentation. <https://stable-baselines3.readthedocs.io/en/master/>
- [3] Fractal. “Guía completa del mantenimiento industrial.” <https://www.fractal.com/es/blog-guia-completa-del-mantenimiento-industrial-estrategias-herramientas-y-mejores-practicas>

5.4 PUBLICACIONES CIENTÍFICAS

En el período de actividad de la Cátedra se han llevado a cabo diferentes publicaciones internacionales dando así difusión a las actividades de investigación que se han llevado a cabo. Dichas publicaciones son las siguientes por orden de fecha de publicación de más antigua a más reciente:

1. **Rubiales Mena, M.C., Muñoz, A., Sanz-Bobi, M.A., González-Calvo, D., Álvarez Tejedor, T., Application of ensemble machine learning techniques to the diagnosis of the combustion in a gas turbine. Applied Thermal Engineering. Vol. 249, pp. 123447-1 - 123447-16, Julio 2024. [Online: Mayo 2024]. JCR: 6,100 Q1 (2023) - SJR: 1,488 Q1 (2023)**

Esta publicación es accesible a todo el público en el enlace <https://www.sciencedirect.com/science/article/abs/pii/S1359431124011153> en una revista de impacto internacional en cuartil Q1 según el indicador JCR. Su contenido resumido es el siguiente:

"This paper describes a method based on the combination of several machine learning techniques, working together in an ensemble, with the aim of continuously monitoring the combustion of a gas turbine in a combined cycle by observing the available exhaust gas temperature measurements and operation condition variables. The goal of this monitoring is the automatic detection of anomalies in the combustion chambers, and possible faults in the measurement thermocouples in the gas turbine as soon as possible. Four gas turbines were studied, each one equipped with twenty-one thermocouples located at the exhaust gas outlet to measure the temperature in each combustion chamber. These sensors are located at the exhaust of the gas turbine, symmetrically distributed on a circle.

The anomaly detection method developed is based on an ensemble that combines models characterizing the normal behavior expected without anomalies but also the analysis of the actual temperatures of the gas turbine. In particular, neural networks and principal component analysis (PCA) have been applied. These models are used to compare the current performance of the gas turbine with past performance in reference periods known as normal operating conditions, in which a homogeneous distribution of exhaust gas temperatures is observed and a functional relationship between these temperatures and the operating variables such as power output must be fulfilled. If the behavior observed is significantly different from what the designed system expects, it is analyzed to find the cause of this anomaly that could be focused on a specific thermocouple or some combustion chambers. The failure will be associated with a combustion chamber failure if several thermocouples from the same combustion chamber are shown as faulty. This is very useful for planning maintenance and for saving time by removing the problem observed. This paper describes the methods used and real cases of application, which have not been applied as a whole independent analysis system in previous researches. The results obtained have validated the strategy proposed.

Gas turbines can fail due to different components, but the main focus of this article will be gas turbines combustor faults".

2. **Anomaly detection of a cooling water pump of a power plant based on its virtual digital twin constructed with deep learning techniques.** M.A. Sanz-Bobi, S. Orbach, F.J. Bellido-López, A. Muñoz, D. González-Calvo, T. Álvarez Tejedor. 8th European Conference of the Prognostics and Health Management Society -PHME24, Praga (República Checa). 03-05 julio 2024.

Esta publicación es accesible a todo el público en el enlace <https://papers.phmsociety.org/index.php/phme/article/view/4004> en una conferencia internacional muy conocida en el ámbito de PHM (Prognostics and Health Management Society). Su contenido resumido es el siguiente:

"This paper aims to explore the use of recent approaches of deep learning techniques for anomaly detection of potential failure modes in a cooling water pump working in a gas-combined cycle in a power plant. Two different deep learning techniques have been tested: neural networks and reinforcement learning. Two virtual digital twins were developed with each family of deep learning techniques, able to simulate the behavior of the cooling water pump in the absence of pump failure modes. Each virtual digital twin consists of several models for predicting the expected evolution of significant behavior variables when no anomalies exist. Examples of these variables are bearing temperatures or vibrations in different pump locations. All the data used comes from the SCADA system. The main features and hyperparameters in the virtual digital twins are presented, and demonstration examples are included".

3. **Casero, M., Sanz-Bobi, M.A., Bellido-López, F.J., Muñoz, A., González-Calvo, D., Álvarez Tejedor, T., Efficiency monitoring of a cooling water pump based on machine learning techniques.** International Journal of Prognostics and Health Management. Vol. 16, n°. 1, pp. 1 - 6, Diciembre 2024. [Online: Enero 2025] JCR: 1,400 Q2 (2023) - SJR: 0,408 Q2 (2023).

Esta publicación es accesible a todo el público en el enlace <https://doi.org/10.36001/ijphm.2025.v16i1.4160> en una revista de impacto internacional en cuartil Q2 según el indicador JCR. Su contenido resumido es el siguiente:

"This paper presents a method for efficiency monitoring of two circulating water pumps working in a combined cycle power plant for cooling the steam coming from a water-steam turbine. The method is based on monitoring the performance of the pumps over time using machine learning techniques that try to discover patterns in the data observed from the pumps. This permits the maintenance staff to assess the possible degradation of the pumps and evaluate the effect of the corrective and preventive maintenance implemented. Some examples of real cases will be presented in the paper to illustrate the method proposed".

4. **F.J. Bellido-López, M.A. Sanz-Bobi, A. Muñoz, D. González-Calvo, T. Álvarez Tejedor. A novel method for evaluation of the maintenance impact in the health of industrial components. Results in Engineering. Elsevier. Vol. 27, pp. 105809-1 - 105809-26, 2025**

Esta publicación es accesible a todo el público en el enlace <https://doi.org/10.1016/j.rineng.2025.105809> en una revista de impacto internacional en cuartil Q1 según el indicador JCR. Su contenido resumido es el siguiente:

"This study presents a novel method for evaluating maintenance effectiveness in industrial systems, built around the concept of "risk curves" as quantitative indicators of failure. By integrating Failure Mode and Effect Analysis (FMEA) with machine learning-based anomaly detection models, the proposed approach constructs risk curves by aggregating normalized deviations from monitored variables. These curves reflect the progression of failure modes in real time and enable a quantitative and accurate assessment of the impact of maintenance actions.

A key contribution of this research is the use of risk curves as an innovative method to continuously track the potential emergence of failure modes and quantify how maintenance actions contribute to reducing their associated risk. Applied to a feedwater pump in a combined-cycle power plant, these curves successfully detected critical failures, such as bearing wear and leaks, months in advance of traditional methods. Moreover, they provided a data-driven means to assess the effectiveness of maintenance actions, demonstrating their role as a determinant factor in improving component condition and mitigating failure risk.

The findings highlight the potential of this methodology to enhance maintenance strategies, reduce downtime, and foster improved collaboration between operation and maintenance teams. This research represents a significant advancement in maintenance evaluation, offering a scalable and data-driven framework that bridges existing gaps in failure diagnostics and decision-making processes".

6

EVENTOS DE FORMACIÓN
Y CAPACITACIÓN

Se han realizado anualmente una serie de actividades de formación y capacitación con las que ha pretendido hacer una labor divulgativa del potencial de las técnicas de inteligencia artificial en diferentes aplicaciones y en diferentes entornos industriales. Seguidamente se detallarán estas actividades.

6.1 WEBINARS SOBRE APLICACIONES DE LA IA

En el período de actividad de la Cátedra se han llevado a cabo diferentes Webinars con el objetivo de divulgar de forma sencilla para todos los interesados una formación introductoria a temas actuales de aplicación de las técnicas de la IA. Estos Webinars se han ido realizando como capítulos de una serie denominada “Horizontes de la IA” y la asistencia en todos ellos ha superado los 100 asistentes. Todos estos webinars son accesibles en la página web de la Cátedra. Se han realizado los siguientes:


1. Webinar I

Ponente: Dr. D. Eugenio Sánchez Úbeda Profesor de Comillas-ICAI

Fecha: 16 de noviembre de 2023

Título: “Deep Learning”

Contexto:



La era del aprendizaje profundo (Deep Learning) ya ha comenzado. En este primer capítulo los protagonistas revisan las ideas principales del DL, para luego introducirse en el apasionante mundo de las redes neuronales convolucionales (CNNs). Se revisan las principales componentes utilizadas para crear CNNs, así como los algoritmos utilizados para ajustar sus pesos. El capítulo termina con la puesta en práctica de los conceptos expuestos creando una CNN desde cero para resolver un problema de clasificación de imágenes.

2. Webinar 2

Ponente: Dr. D. Alvaro Jesús López López, Profesor Investigador de Comillas – ICAI

Fecha: 7 de marzo de 2024

Título: “Introducción a la IA generativa como una herramienta de mejora de la productividad”

Contexto:



La inteligencia artificial (IA) generativa abre la puerta a un sinfín de aplicaciones de automatización que hace unos meses eran impensables. Además, a diferencia de las tecnologías previas de IA, la interacción con estas máquinas se desarrolla en un lenguaje ciertamente próximo al lenguaje natural humano, lo que puede democratizar su uso como nunca antes hemos visto con herramientas de este nivel de sofisticación. En este seminario online interactivo vamos a comenzar analizando cómo ha aparecido este nuevo “sabor” de la IA. Seguiremos viendo cuáles son las herramientas más prometedoras disponibles y terminaremos presentando ejemplos de uso con el objetivo de informarte e inspirarte para que puedas emplear modelos de IA generativa de forma eficaz en tu día a día.


3. Webinar 3

Ponente: Dr. D. Mario Castro Ponce, Director del Departamento de Telemática y Computación de Comillas - ICAI

Fecha: 5 de noviembre de 2024

Título: “Si la correlación no implica causalidad, ¿gentonces qué?”

Contexto:



La IA basada en modelos causales analiza patrones en los datos para identificar relaciones que representan las dependencias de causa y efecto entre variables. En este webinar se aborda la definición de modelos causales y cómo pueden usarse en predicción. Los modelos causales abren una nueva vía para soportar decisiones en IA. El contenido del webinar es el siguiente:

- Modelos causales. Concepto y componentes de los mismos.
- Aproximación bayesiana a la predicción.
- La IA causal como nuevo paradigma que puede complementar la IA actual.

4. Webinar 4

Ponente: Dr. D. Jesús Tordesillas Torres Profesor de Comillas - ICAI

Fecha: 21 de marzo de 2025

Título: “¿Cómo consigue un robot volar, andar, o hacer parkour?”

Contexto:



En este webinar se estudiará el problema de la planificación de trayectorias en entornos dinámicos utilizando tanto enfoques basados en la optimización como enfoques basados en el aprendizaje. Se mostrará como se puede aprovechar el aprendizaje por refuerzo para hacer que los robots cuadrúpedos aprendan a andar, correr y hacer parkour.

5. Webinar 5

Ponente: Dr. D. Pablo Sánchez Pérez, Profesor de Comillas - ICAI

Fecha: 17 de octubre de 2025

Título: “Recomiéndame algo: el poder (y los retos) de los sistemas de recomendación”

Contexto:



Los sistemas de recomendación están presentes en nuestra vida diaria. Plataformas de películas y música hasta tiendas online o aplicaciones de turismo hacen uso de estos sistemas para recomendar sus productos a los usuarios de manera personalizada. Para realizar estas recomendaciones, los sistemas de recomendación analizan los patrones de consumo de cada usuario para seleccionar aquellos artículos que más se adapten a sus necesidades e intereses. En este webinar, se explora de manera introductoria los principales tipos de sistemas de recomendación, así como algunas de las técnicas más conocidas empleadas en el área. También se aborda cómo evaluar la calidad de las recomendaciones producidas, más allá de la precisión (acierto o relevancia), analizando dimensiones como la novedad, la diversidad o la cobertura (tanto de artículos como de usuarios). Finalmente, se discuten también algunos de los desafíos de estos sistemas, como los sesgos, o la equidad en las recomendaciones producidas.

6.2 DATATHON



Es un evento anual que reúne a estudiantes de ICAI y empleados de Endesa, promovido por el CEO de Endesa, con el objetivo de difundir el uso de IA en el sector energético. Se han celebrado dos ediciones: noviembre de 2023 y noviembre de 2024.

Esta competición se celebra en la sede de la compañía en Madrid y supone un desafío a resolver en unas 3 horas. Participan más de 70 alumnos de 3º de Ingeniería Matemática e Inteligencia Artificial y 5º del Doble Grado en Ingeniería en Tecnologías de Telecomunicación y Business Analytics de la Universidad Pontificia Comillas ICAI, acompañados por unos 20 empleados de Endesa.

En todas las ediciones los tres equipos que consiguen los mejores resultados de predicción reciben un diploma y exponen sus modelos de datos, resultados, y en general, y el proceso que han llevado a cabo hasta la solución, al equipo directivo de Endesa.

En la edición de 2023 se tuvo que afrontar el reto por equipos de ser capaz de predecir la producción eléctrica de la isla de Tenerife utilizando datos históricos del negocio.



Figura 66. Participantes de la edición de noviembre de 2023



DATATHO

TA
ON

DATATHO

Figura 67. Algunos momentos del desarrollo del Datathon de noviembre de 2023

En la edición de 2024 se tuvo que afrontar el reto por equipos de ser capaz de estimar la producción generada por la CTCC Besós para el período 1/9/2024 a 15/9/2024 utilizando datos históricos del negocio.



Figura 68. Participantes de la edición de Noviembre de 2024



Figura 69. Equipos ganadores y staff de Datathon de la edición de noviembre de 2024

6.3 JORNADAS TÉCNICAS



Las Jornadas Técnicas se celebran anualmente y su objetivo básico es compartir experiencias sobre técnicas y aplicaciones de la IA en mantenimiento industrial en sectores de diferente naturaleza que el eléctrico, con ello se busca poner la atención en cómo otros sectores industriales utilizan las técnicas de Inteligencia Artificial al mismo tiempo de enriquecer el conocimiento propio de la Cátedra y la divulgación de las actividades de la misma.



El **19 de septiembre de 2023** se celebró la **primera edición** de estas Jornadas que tuvo como contenidos esenciales las siguientes presentaciones con sus correspondientes ponentes:

- *Experiencias en aplicaciones de Inteligencia Artificial al mantenimiento basado en datos.*
Ponentes: D. Tomás Álvarez Tejedor, D. Daniel González Calvo y D.ª Diana Alfonso Estrada, **Endesa**.
- *Transformación Digital. La IA como tecnología clave.*
Ponente: D. Donato Martínez Pérez de Rojas, **Navantia**.
- *Detección de anomalías en equipos industriales con técnicas de IA.*
Ponente: D.ª Julia Díaz García, **Repsol**.



El **23 de octubre de 2024** se celebró la **segunda edición** de estas Jornadas que tuvo como contenidos esenciales las siguientes presentaciones con sus correspondientes ponentes:

- *La aplicación de Inteligencia Artificial al Mantenimiento Basado en Datos.*
Ponente: D. Tomás Álvarez, **Endesa**, Head of Gas and Coal Maintenance Iberia.
- *GMTwin en la gestión del mantenimiento centralizado.*
D. Daniel González, **Endesa**, Experto en Proyectos de Producción y Mantenimiento Basado en Datos.
- *SinergIA.*
Ponentes: D.ª María Cuencas, **Endesa**, Agile Coach y D. Javier Espinosa, **Endesa**, Responsable de la Oficina de Transformación Agile.
- *IA aplicada en el Health Management de aeronaves militares: diagnóstico y mantenimiento predictive.*
Ponente: D.ª Rocío Martín Martín, **Airbus**, Data Analyst for Predictive Maintenance at Airbus.
- *Analítica avanzada en el sector del ferrocarril. Casos de uso enfocados tanto al operador como al mantenedor.*
Ponente: D. Vicente Gutiérrez, **CAF**, Maintenance Engineer.
- *Antolin Digital Twin: Evolución del 4.0 al 5.0.*
Ponente: D.ª Lorena Gil López, **Grupo Antolin**, Chief Digital Information & Data Officer.




El **21 de octubre de 2025** se celebró la **tercera edición** de estas Jornadas que tuvo como tema fundamental Salud, Seguridad Laboral) e IA con los siguientes temas y ponentes invitados:

- *Cuando la IA come basura: La dieta que pone en riesgo los datos y la salud.*
Ponente: Elisabeth Arrojo: Directora médica del **Instituto Médico de Oncología Avanzada** (INMOA).
- *El gran reto: Proteger la visión en tiempos de la IA.*
Ponente: Nilo Garcia Manchado, CEO de **Reticare**.
- *Generación de Mamografías sintéticas - Perspectiva general y retos en síntesis de imagen.*
Ponente: Alberto Gutierrez Torre, Investigador del **Barcelona Supercomputing Center - Centro Nacional de Supercomputación** (BSC-CNS).



Figura 70. Ponentes de la II Jornada Técnica junto al equipo de Dirección de la Cátedra ENDESA-ICAI

6.4 CURSOS DE FORMACIÓN



Entre el 10 y el 16 de diciembre de 2024 tuvo lugar un curso de formación para personal de ENDESA con el título: **“Introducción al procesamiento de imagen para reconocimiento de objetos”**.

Ponentes: Dr. Jaime Boal Martín-Larrauri y Dr. Jaime Pizarroso Gonzalo.

El objetivo de este programa formativo es mejorar la competencia en el uso de herramientas de procesamiento de imágenes, permitiendo a los profesionales de Endesa abordar proyectos de reconocimiento de objetos de manera más efectiva. Se persigue proporcionar conocimientos básicos sobre los algoritmos existentes y desarrollar un mayor criterio para interactuar con proveedores de soluciones externos y los propios desarrolladores de la compañía.

Técnicas utilizadas:

Visión por ordenador, aprendizaje profundo, redes neuronales convolucionales (CNN).

Líneas de investigación:

Análisis de datos.

7

VALOR DE LAS APORTACIONES
DE LA CÁTEDRA

Como se ha venido comentando en las secciones anteriores el Mantenimiento Basado en Datos (MBD) es el modelo que sustenta esta Cátedra, y que tiene como soporte los siguientes pilares fundamentales:

- 1. **Cambio Cultural hacia un Enfoque Digital en el Mantenimiento:** Se ha promovido un cambio cultural que incorpora tecnologías avanzadas, como la IA, para anticipar fallos y optimizar las intervenciones de mantenimiento. Esto mejora la fiabilidad y reduce los tiempos de inactividad.
- 2. **Digitalización de la Gestión del Mantenimiento:** GMDigital ha permitido centralizar todos los datos y procesos de mantenimiento, facilitando la toma de decisiones con información precisa sobre la operación, gestión económica y control del mantenimiento.
- 3. **Mantenimiento Prescriptivo:** Además, se integra el mantenimiento prescriptivo, que no solo predice fallos, sino que prescribe intervenciones correctivas antes de que ocurran. Este enfoque permite una gestión más eficiente, proactiva y sostenible.

Bajo esa perspectiva y para concluir esta memoria se puede decir que la Cátedra de Aplicaciones de la IA al Mantenimiento Basado en Datos en sus tres años de vida ha demostrado ser un motor clave para la transformación digital de Endesa. A través de proyectos innovadores que aplican IA y aprendizaje automático, Endesa ha optimizado la fiabilidad de los equipos, reducido costes operativos y mejorado la eficiencia del mantenimiento. La plataforma GMDigital ha creado una solución global que está en proceso de expansión internacional a todo el grupo Enel, marcando el camino hacia un mantenimiento más proactivo y sostenible en el sector energético.

Por su parte la Cátedra ha hecho posible hasta el momento la investigación a través de dos tesis doctorales en curso usando técnicas punteras de aplicación a la solución de problemas reales y ha facilitado la puesta en contacto de alumnos de último curso de Máster y de Grado con problemas industriales reales que han tratado en sus seis respectivos Trabajos de Final de Ciclo Académico.

Así mismo está siendo muy atractiva la celebración anual de un Datathon con alumnos desplazados a ENDESA para resolver problemas de carácter real y las Jornadas técnicas y webinars que se vienen celebrando de manera regular. En definitiva, la Cátedra está posibilitando a los alumnos de Comillas la posibilidad de una formación adicional académica en un entorno de trabajo de problemas reales y a ENDESA el conocer y disponer de nuevos instrumentos basados en técnicas de Inteligencia Artificial que ayudan a resolver problemas reales de una manera más eficiente y con mejores criterios para su solución.



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

ICADE

CIHS

© Universidad Pontificia Comillas

EDITA:

Cátedra aplicaciones de la IA al mantenimiento basado en datos

DISEÑO Y REALIZACIÓN:

Alcuadrado, Diseño y Comunicación, S.L.



comillas.edu