

Trabajo Fin de Grado

En Ingeniería de las Tecnologías Industriales


Aplicación de la ingeniería de datos al
mantenimiento predictivo de sistemas de
climatización y refrigeración

Autor: Pedro García Prado

Tutor: Juan F. Coronel Toro

Dpto. Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2026



Trabajo Fin de Grado
En Ingeniería de las Tecnologías Industriales

Aplicación de la ingeniería de datos al mantenimiento predictivo de sistemas de climatización y refrigeración

Autor:

Pedro García Prado

Tutor:

Juan F. Coronel Toro

Profesor titular

Dpto. de Ingeniería Energética
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2026

Trabajo Fin de Grado: Aplicación de la ingeniería de datos al mantenimiento predictivo de sistemas de climatización y refrigeración

Autor: Pedro García Prado

Tutor: Juan F. Coronel Toro

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2026

El Secretario del Tribunal

A mi madre Lola

Gracias

AGRADECIMIENTOS

En primer lugar, tengo que agradecer a mi profesor Luis. Si no fuera por él, no sé si estaría escribiendo estas líneas. Por supuesto, también a mi tutor Juan, que me ha guiado en este trabajo con paciencia y del que he aprendido mucho durante estos meses.

Como cada vez que alcanzo un objetivo, quiero agradecer a mi madre Lola, que incondicionalmente, con resultados buenos y malos, momentos alegres y tristes, siempre está ahí con las palabras adecuadas y con una sonrisa que borra todo lo malo. A mi hermanito Jeff, porque sin darse cuenta me inspira a intentar ser mejor persona cada día. Y a mi novia Sandra, porque ha estado presente en este proyecto desde el principio, probablemente con el papel más difícil, apoyándome y guiándome durante todo el proceso. Es raro el día que no aprendo algo de ella.

Por último quiero darle las gracias a Nabil, porque su amistad es de esas que te cambian la vida.

El mantenimiento predictivo se ha consolidado en las últimas décadas como una herramienta clave en el ámbito industrial, al permitir la anticipación de fallos mediante el análisis continuo de variables operativas críticas. Su implementación contribuye a reducir las paradas imprevistas, optimizar la disponibilidad de los equipos y mejorar la eficiencia global de los procesos productivos.

Este Trabajo de Fin de Grado aborda el estudio y la aplicación del mantenimiento predictivo en sistemas HVAC (Heating, Ventilation and Air Conditioning) usando como herramienta principal el lenguaje de programación Python.

En la primera parte establecemos el marco teórico en el que desarrollamos los fundamentos del mantenimiento predictivo, destacando su evolución y ventajas con respecto a otros tipos de mantenimiento y sus posibles aplicaciones en el ámbito industrial. A continuación lo aplicamos a un caso práctico-teórico simulando datos de funcionamiento en un sistema HVAC. El objetivo de esta parte es demostrar como utilizando estas técnicas se pueden anticipar gran parte de las averías, optimizando el mantenimiento y reduciendo costes operativos.

En paralelo a la utilidad del mantenimiento predictivo, se muestran también las cualidades de Python como herramienta para el desarrollo de este tipo de mantenimiento en sistemas críticos como son los HVAC.

ABSTRACT

Predictive maintenance has become established over the past few decades as a key tool in the industrial sector, enabling the anticipation of failures through continuous analysis of critical operational variables. Its implementation helps reduce unexpected downtimes, optimize equipment availability, and improve the overall efficiency of production processes.

This document explores the study and application of predictive maintenance in HVAC (Heating, Ventilation, and Air Conditioning) systems, using the Python programming language as the main tool.

In the first part, we establish the theoretical framework by developing the fundamentals of predictive maintenance, highlighting its evolution, advantages over other types of maintenance, and its potential applications in the industrial field. We then apply these concepts to a practical-theoretical case by simulating operating data in an HVAC system. The objective of this section is to demonstrate how these techniques can be used to anticipate a large portion of failures, thereby optimizing maintenance and reducing operating costs.

Alongside the usefulness of predictive maintenance, the capabilities of Python as a tool for developing this type of maintenance in critical systems such as HVAC are also showcased.

Agradecimientos.....	ix
Resumen	xi
Abstract	xii
Índice	xiii
ÍNDICE DE TABLAS.....	xvii
ÍNDICE DE FIGURAS	xix
1 Introducción.....	1
1.1. Justificación del trabajo	1
1.2. Objetivos.....	1
1.3. Estructura del trabajo.....	2
2 Marco Teórico	4
2.1. Tipos de mantenimiento	5
2.1.1 Mantenimiento correctivo.....	5
2.1.2 Mantenimiento preventivo.....	5
2.1.3 Mantenimiento predictivo.....	5
2.2. Fundamentos del mantenimiento predictivo.....	5
2.2.1 Principio básico del mantenimiento predictivo	6
2.2.2 Objetivos del mantenimiento predictivo.....	6
2.2.3 Tecnologías y técnicas asociadas al Mantenimiento predictivo	6
2.2.4 Fases del Mantenimiento Predictivo.....	9
2.2.5 Ventajas del Mantenimiento Predictivo.....	12
2.2.6 Desventajas del Mantenimiento Predictivo	14
2.2.7 Conclusiones.....	15
3 Sistemas de climatización	17
3.1. Mantenimiento predictivo en sistemas de climatización	18
3.2. Tipos de sistemas de climatización	18
3.2.1 Unidades autónomas (packaged units)	19
3.2.2 Sistemas centrales.....	20
3.3. Componentes principales de los sistemas de climatización	21
3.3.1 Unidad de calefacción (Heating)	22
3.3.2 Unidad de enfriamiento (Air Conditioning)	22

3.3.3 Sistema de ventilación (Ventilation)	22
3.3.4 Conductos y tuberías	23
3.3.5 Dispositivos de control	23
3.4. Eficiencia energética en sistemas de climatización	23
3.4.1 Indicadores de eficiencia instantáneos y estacionales	24
3.4.2. Sistemas de regulación inteligente	25
3.4.3. Integración de energías renovables.....	25
4 Refrigeración industrial	27
4.1. Principios de la refrigeración industrial.....	27
4.2. Funcionamiento de los congeladores industriales	28
4.3. Modos de fallo comunes.....	28
4.4. Mantenimiento predictivo en congeladores.....	29
5 Caso práctico 1 – rooftop unit	30
5.1. Conjunto de datos utilizado	30
5.1.1. Variables registradas.....	30
5.1.2. Formato y carga del conjunto de datos.....	32
5.1.3. Descripción estadística inicial	34
5.2. Preparación y tratamiento de los datos	35
5.2.1. Variables registradas y significado físico.....	35
5.2.2. Preprocesamiento inicial del conjunto de datos.....	36
5.2.3. Ingeniería de características orientada a la eficiencia energética	36
5.3. Análisis exploratorio de datos (EDA)	40
5.3.1. Comportamiento operativo general del sistema	40
5.3.2. Evolución temporal del caudal de aire.....	45
5.3.3. Evolución temporal del EER	45
5.3.4. Distribución estadística del EER	46
5.3.5. Relación entre eficiencia, temperatura exterior y condiciones de evaporación.....	48
5.3.6. Análisis de las cargas térmicas sensible y latente.....	54
5.3.7. Dependencia entre variables principales	58
5.4. Simulación de fallos	61
5.4.1. Enfoque de la simulación de fallos.....	61
5.4.2. Selección de fallos simulados.....	61
5.4.3. Simulación de ensuciamiento del evaporador	61
5.4.4. Simulación de pérdida de caudal de aire	63
5.4.5. Simulación de degradación del compresor.....	64
5.4.6. Generación de etiquetas de fallo.....	65
5.5 Modelado predictivo en Python.....	65
5.5.1 Objetivo del modelado predictivo	66
5.5.2. Definición del problema y variable objetivo	66

5.5.3. Selección y significado físico de las variables de entrada.....	66
5.5.4 Preparación del conjunto de datos	67
5.5.5 Selección del algoritmo Random Forest.....	68
5.5.6 Entrenamiento del modelo.....	68
5.5.7 Evaluación del rendimiento del modelo	68
5.5.8 Interpretabilidad del modelo.....	71
5.5.9 Discusión y limitaciones.....	71
6 Caso práctico 2 - Congeladores	72
6.1. Dataset utilizado	72
6.2. Variables clave e indicadores	73
6.3. Activaciones de mantenimiento.....	73
6.3.1. Representación conjunta.....	74
6.3.2. Representación individual por congelador	76
6.4. Reglas de activación de mantenimiento	81
6.5. Visualización de activaciones de mantenimiento	82
6.6. Conclusión.....	83
7 Conclusiones	84
7.1. Conclusiones generales.....	84
7.2. Contribuciones del trabajo.....	85
7.3. Trabajos futuros.....	85
Referencias	89
Glosario	91

ÍNDICE DE TABLAS

Tabla 2.1: Variables habitualmente monitorizadas en sistemas de climatización para M.P.	11
Tabla 5.1: Variables objetivo recogidas por los sensores integrados en la RTU	31
Tabla 6.1: Formato de los datos recogidos en los congeladores	72

ÍNDICE DE FIGURAS

Figura 2.1. Evolución de la tecnología de mantenimiento	4
Figura 3.1: esquema típico de sistema de climatización autónomo	18
Figura 3.2: Estructura típica de un sistema de climatización central	19
Figura 4.1: Ciclo de refrigeración industrial	27
Figura 5.1: Esquema de la unidad Rooftop y sus principales variables	32
Figura 5.2: información general sobre variables del conjunto de datos	33
Figura 5.3: Descripciones estadísticas de ambos días del conjunto de datos	34
Figura 5.4: Evolución temporal de las potencias eléctricas del día 1	41
Figura 5.5: Evolución temporal de las potencias eléctricas del día 2	41
Figura 5.6: Evolución temporal de las temperaturas el día 1	43
Figura 5.7: Evolución temporal de las temperaturas el día 2	43
Figura 5.8: Evolución temporal del flujo de aire en el evaporador	45
Figura 5.9: Evolución temporal del EER instantáneo del sistema	46
Figura 5.10: Distribución estadística (histograma) del EER de la unidad rooftop	47
Figura 5.11: Tabla comparativa de los regímenes de 1 y 2 compresores	48
Figura 5.12: Relación entre EER y temperatura exterior del aire	49
Figura 5.13: Relación entre fracción de aire exterior y temperatura exterior	51
Figura 5.14: Evolución temporal de la fracción de aire exterior	52
Figura 5.15: Evolución temporal de las temperaturas ECT, RET y OT	53
Figura 5.16: Relación entre EER y temperatura del aire de mezcla	53
Figura 5.17: Evolución temporal de las cargas latente y sensible	55
Figura 5.18: Evolución temporal del factor de calor sensible (FCS)	56
Figura 5.19: Evolución conjunta de la carga térmica total, potencia de compresión y EER	58
Figura 5.20: Matriz de correlación de las variables principales	60
Figura 5.21: comparativa entre EER en condiciones normales y con el evaporador sucio	62
Figura 5.22: comparativa entre EER tras disminución del flujo de aire en el evaporador	63
Figura 5.23: comparativa entre EER con degradación de comportamiento en el compresor	65
Figura 5.24: Atributos de evaluación del modelo	69
Figura 5.25: Matriz de confusión del sistema	70
Figura 5.26: Importancia de las variables en el modelo de mantenimiento predictivo	71

Figura 6.1: Temperatura de todos los congeladores en franja reducida de temperaturas	75
Figura 6.2: Temperatura de todos los congeladores en franja completa de temperaturas	76
Figura 6.3: Temperatura del congelador 1	77
Figura 6.4: Temperatura del congelador 2	77
Figura 6.5: Temperatura del congelador 3	78
Figura 6.6: Temperatura del congelador 4	78
Figura 6.7: Temperatura del congelador 5	79
Figura 6.8: Temperatura del congelador 6	79
Figura 6.9: Temperatura del congelador 7	79
Figura 6.10: Temperatura del congelador 8	80
Figura 6.11: Temperatura del congelador 9	80
Figura 6.12: Temperatura del congelador 10	80
Figura 6.13: Puntos de mantenimiento requerido del congelador 2	82

1 INTRODUCCIÓN

“Hay nacimiento, hay muerte y entre medias hay mantenimiento”

- Tom Robbins -

1.1. Justificación del trabajo

El mantenimiento predictivo se ha establecido como una de las claves para la gestión eficiente de útiles y medios industriales. En un contexto en el que tanto la eficiencia energética como la económica (reducción de costes operativos y mayor tiempo de funcionamiento posible) y la sostenibilidad son fundamentales, aplicar este enfoque al mantenimiento resulta muy útil, incluso imprescindible en algunos casos.

Particularmente, los sistemas HVAC (Heating, Ventilation and Air Conditioning, en adelante sistemas de climatización) tienen un papel insustituible en la climatización de edificios industriales. Debido a que su funcionamiento suele extenderse durante períodos largos sin parar y a que las condiciones operativas externas a las que están sometidos varían continuamente son susceptibles a fallos que se traducen en: pérdidas de eficiencia energética, disminución de la comodidad de los usuarios o trabajadores y aumentos en los costes de producción. En algunos procesos, el producto queda inservible si la temperatura sale de cierto rango, lo que hace que sea prioritario adelantarse a las averías que pueden provocar una interrupción en la climatización y la pérdida de producto.

Las herramientas de programación como Python permiten implementar estrategias de mantenimiento predictivo precisas y eficientes basadas en la recogida y análisis de datos, sin añadir costes adicionales de software. En este trabajo se cruzan ingeniería aplicada, programación y mantenimiento de activos, competencias muy presentes en el mercado laboral actual.

Este trabajo se justifica por la necesidad creciente de disponer de herramientas capaces de anticipar fallos, optimizar recursos y mejorar la eficiencia energética en sistemas industriales críticos. La combinación de técnicas de ingeniería de datos y mantenimiento predictivo constituye una solución especialmente adecuada para alcanzar estos objetivos.

1.2. Objetivos

El objetivo general de este trabajo es desarrollar una metodología de mantenimiento predictivo basada en ingeniería de datos utilizando Python y aplicarla a sistemas de climatización y refrigeración industrial.

Los objetivos específicos son los siguientes:

- Establecer el marco teórico del mantenimiento predictivo en el ámbito industrial
- Estudiar el funcionamiento de los sistemas de climatización, sus características y sus puntos y valores críticos
- Analizar un conjunto de datos reales de un sistema de climatización industrial y generar escenarios de funcionamiento degradado mediante simulación de fallos.
- Evaluar los resultados obtenidos en cuanto a precisión y utilidad.
- Repetir este proceso para el caso real de los congeladores industriales.

1.3. Estructura del trabajo

El contenido y la estructura del trabajo se divide en tres grandes bloques: un primer bloque teórico (capítulos 2, 3 y 4), una segunda parte (capítulo 5) en el que se aplica al teoría expuesta sobre un sistema de climatización tipo RTU (rooftop unit) con datos reales simulados, y una tercera parte (capítulo 6) en la que se analiza un caso real de congeladores industriales.

En el capítulo 2 se encuadran las bases conceptuales del mantenimiento predictivo dentro de la evolución del mantenimiento industrial desde principios del siglo XX. Se analiza su relevancia en sistemas de climatización y se repasan las principales herramientas tecnológicas disponibles en la actualidad, con especial interés en la ciencia de datos para cuya implementación en este trabajo utilizaremos el lenguaje de programación Python y sus bibliotecas especializadas más importantes.

En el capítulo 3 se describen los tipos de sistemas de climatización, sus componentes principales y el principio de funcionamiento, además de los coeficientes fundamentales utilizados para cuantificar su eficiencia.

En el capítulo 4 se exponen los principios de la refrigeración industrial, el funcionamiento de los congeladores y sus modos de fallo principales, terminando con una introducción teórica al mantenimiento predictivo en congeladores de cara al caso práctico del capítulo 6.

En el capítulo 5 se desarrolla un caso práctico de mantenimiento predictivo sobre una unidad rooftop. A partir de datos reales de funcionamiento se aplican técnicas de ingeniería de datos mediante Python con el objetivo de detectar condiciones operativas anómalas y anticipar posibles fallos.

En capítulo 6 analizamos un caso real de sistemas de refrigeración (congeladores) de producto sellante de una fábrica en un entorno industrial. Mediante únicamente sensores de temperatura y de forma similar al caso de la unidad rooftop analizada en el capítulo anterior, vemos como se pueden analizar los datos para detectar estados o condiciones que puedan llevar a futuros fallos o deterioros en los sistemas. Se obtienen de igual forma conclusiones a partir de estos datos y sus resultados.

2 MARCO TEÓRICO

La llegada de la industria 4.0 ha significado una revolución dentro del ámbito industrial, caracterizada por la introducción de tecnologías digitales actuales en los procesos de producción y que tiene como objetivo lograr fábricas más eficientes, capaces de sobrevivir en el mercado actual.

Dentro de este contexto, el mantenimiento predictivo, que dio lugar a la industria 3.0 mediante el uso de sensores y sistemas de control, ha evolucionado gracias a las tecnologías digitales mencionadas, convirtiéndose en una herramienta más precisa, inteligente y eficiente, capaz de analizar volúmenes mucho mayores de datos y de anticipar fallos en tiempo real con mayor fiabilidad.




Figura 2.1. Evolución de la tecnología de mantenimiento

2.1. Tipos de mantenimiento

El mantenimiento en el ámbito industrial se encuentra en su cuarta generación (Figura 2-1: Evolución del Mantenimiento Industrial). Cada una de estas generaciones ha estado representada por el tipo de mantenimiento utilizado y su relación con las tecnologías contemporáneas.

2.1.1 Mantenimiento correctivo

La primera generación de mantenimiento industrial seguía un plan de acción completamente reactivo. Solo se actuaba para arreglar equipos o componentes una vez que ya se había producido el fallo.

Esto representa multitud de desventajas y aspectos negativos. El tiempo fuera de servicio no planeado se dispara y se traduce en costes económicos por retraso en la producción y rotura de componentes. Adicionalmente, en algunos medios industriales, el funcionamiento con uno o más componentes dañados puede suponer averías en otras piezas.

Actualmente este tipo de mantenimiento se reserva para piezas baratas, fácilmente sustituibles y que no representan ningún riesgo para otros componentes durante un mal funcionamiento.

2.1.2 Mantenimiento preventivo

Tras la II Guerra Mundial se desarrolló la segunda generación de estrategias de mantenimiento (industria 2.0), y apareció el mantenimiento preventivo. Su característica principal es la intervención sobre los componentes (limpieza, sustitución...) en función a un determinado intervalo de tiempo e independientemente de la condición.

En este tipo de mantenimiento se plantea una cuestión clave: encontrar el equilibrio entre una frecuencia demasiado elevada, buscando un margen de seguridad amplio, lo que aumenta los costes de mantenimiento, y una demasiado baja, con la que se corre el riesgo de que las piezas lleguen al fallo, con los costes operativos que ello puede acarrear.

2.1.3 Mantenimiento predictivo

Tiene su origen en la década de 1980 y su auge en la de 1990. Actualmente experimenta una nueva evolución gracias a la variedad de herramientas tecnológicas disponibles.

El mantenimiento predictivo surge de la necesidad de optimizar los costes técnicos, humanos y económicos del mantenimiento preventivo. Minimizar el tiempo de parada no deseado de los medios a la vez que se maximiza la vida útil de sus componentes se ha convertido en una necesidad vital para ser competente en el mercado de la industria [4], [10].

2.2. Fundamentos del mantenimiento predictivo

El mantenimiento predictivo es una técnica utilizada para pronosticar en qué momento futuro tendrá lugar la avería de un componente determinado del medio industrial sobre el que se aplique. Esto permite diseñar un plan para actuar sobre el componente, arreglándolo o sustituyéndolo cuando el fallo sea inminente. De esta forma se reducen el coste de mantenimiento y el tiempo de parada no deseado del útil mientras se maximiza el tiempo de vida de sus componentes [4], [9].

El objetivo es mantener unos niveles de servicio óptimos en los equipos, programando las revisiones, reparaciones y sustituciones en momentos de parada de servicio, reduciendo al mínimo el impacto del mantenimiento sobre el tiempo de funcionamiento. Se busca intervenir cuando el equipo no haya dado aún ningún síntoma de malfuncionamiento, pero algunos de los datos recogidos sobre los estados de los componentes indican que el fallo está próximo.

2.2.1 Principio básico del mantenimiento predictivo

El mantenimiento predictivo se basa en la idea de que gran parte de las averías en medios industriales no se producen repentinamente, sino que las preceden determinados estados anómalos, cambios físicos o funcionales que pueden ser detectados antes de que llegue el fallo. Los estados analizados más frecuentemente son vibraciones no habituales, temperaturas fuera de los rangos nominales, ruidos o descensos en la eficiencia, entre otros.

2.2.2 Objetivos del mantenimiento predictivo

Los objetivos más importantes del mantenimiento predictivo aplicado a los medios industriales son:

- Reducción de los tiempos de parada no planificados
- Maximizar la vida útil de los componentes y activos
- Optimización de los recursos técnicos, humanos y económicos
- Reducción de los costes operativos y de mantenimiento a medio y largo plazo
- Aumento de la seguridad y prevención de riesgos
- Mejora de la eficiencia energética de los procesos de producción.

El cumplimiento de estos objetivos permite a las empresas ser más eficientes y aumentar su fiabilidad de cara a los procesos productivos [5], [10].

2.2.3 Tecnologías y técnicas asociadas al Mantenimiento predictivo

El mantenimiento predictivo se basa en una serie de técnicas de monitorización y análisis de datos. Las más utilizadas comúnmente son:

2.2.3.1 Análisis de vibraciones

Es la técnica principal para diagnosticar la maquinaria rotativa y poder establecer un plan de mantenimiento en función de los resultados.

Se empieza a aplicar en la industria en las décadas de 1960 y 1970 mediante medidores analógicos, por lo que el análisis de componentes como rodamientos y engranajes no daba como resultado diagnósticos demasiado fiables.

La incorporación de filtros sintonizables aumento de forma significativa la precisión de los diagnósticos, pero no fue hasta la década de 1980, con la irrupción en este ámbito de los equipos

digitales y el uso de la Transformada Rápida de Fourier (FFT, Fast Fourier Transform) que se pudo tratar la información de forma masiva y en tiempo real.

Parámetros frecuentes de supervisión

- Vibraciones en bandas ancha y estrecha de frecuencia
- Medida de parámetros específicos de vibración para detectar fallos en rodamientos y engranajes
- Parámetros de la forma de onda: simetría y cresta
- Fase vibratoria en armónicos
- Medida de vibraciones síncronas, sub-síncronas y no síncronas

Principales fallos a detectar

- Desequilibrio
- Desalineación
- Holguras
- Rozamiento excesivo
- Ejes desalineados o torcidos
- Poleas excéntricas
- Rodamientos desgastados
- Engranajes
- Fallos eléctricos

2.2.3.2 Termografía infrarroja

La termografía infrarroja es una técnica que permite medir temperaturas a distancia, sin necesidad de que haya contacto físico con el medio bajo estudio, visualizando la radiación infrarroja que emiten los cuerpos mediante una cámara termográfica.

Esta cámara convierte la energía irradiada en una imagen visible, en la que los colores varían en función de la temperatura superficial de los objetos enfocados en cada uno de sus puntos.

Aplicaciones de la termografía infrarroja

El uso principal de la termografía es la inspección de armarios eléctricos, aunque existen multitud de aplicaciones útiles de prevención:

- En motores eléctricos se pueden buscar fallos en el estator
- Lubricación deficiente en cojinetes y rodamientos que provocan calentamientos
- Inspección del estado de aislamiento en hornos y calderas
- Comprobación del sistema de refrigeración en motores eléctricos.
- Inspecciones de centros de transformación de alta tensión
- Comprobación del equilibrio entre fases en líneas eléctricas

Ventajas de la termografía infrarroja

En la línea del mantenimiento predictivo, la termografía permite identificar y diagnosticar problemas en una fase inicial, donde se puedan corregir con el coste más bajo y no se traduzca en daños en otros componentes o productos.

Entre las ventajas de usar cámaras termográficas a modo preventivo están que son fáciles de usar, similares a cámaras fotográficas o de video digitales. Miden las temperaturas en todos los puntos del objeto que estemos enfocando, y permiten inspeccionar sistemas completos sin detener o modificar su funcionamiento.

Por último, es digno de mención que mediante la termografía podemos detectar fugas de sustancias químicas e inflamables, que pueden dar lugar a emisiones graves de gases tóxicos, explosiones o incendios que pongan en peligro tanto las instalaciones como su entorno, pero que detectadas en una fase temprana son fácilmente subsanables [8].

2.2.3.3 Análisis de aceites y lubricantes

Esta técnica consiste en analizar las propiedades físico-químicas del lubricante para detectar indicios de desgaste, contaminación o degradación. Entre los parámetros más habituales se encuentran la viscosidad, el contenido de agua, la presencia de partículas metálicas y la composición química del aceite. Su estudio permite identificar problemas internos en componentes mecánicos antes de que se produzca una avería significativa [6].

2.2.3.4 Ultrasonidos

La captación de ultrasonidos es una técnica que permite detectar fallos que no se podrían detectar con ninguna otra.

Hay un buen número de fenómenos que emiten sonidos por encima de la frecuencia del rango audible, lo que hace posible el uso de detectores de ultrasonidos para intervenir en el origen de las averías mediante múltiples aplicaciones:

- Detección de fugas
- Inspecciones eléctricas
- Control de válvulas y elementos mecánicos [7]

2.2.3.5 Monitoreo de condiciones eléctricas

El monitoreo de condiciones constituye una de las bases del mantenimiento predictivo moderno y consiste en la supervisión continua de variables operativas mediante sensores y sistemas de adquisición de datos.

Se enfoca en la medición y el análisis de los parámetros de los activos en tiempo real. El propósito de esta técnica es realizar el mantenimiento cuando aparece una disminución del rendimiento o se prevé que algún componente va a fallar de forma inminente.

Aunque la implantación inicial puede requerir inversiones elevadas, una vez implementado suele generar reducciones significativas en los costes operativos y energéticos.

Los datos más comunes con los que trabaja el monitoreo de condiciones eléctricas son voltaje, corriente, potencia, factor de potencia y armónicos, entre otros. Mediante sensores avanzados y software de análisis se procesan e interpretan los datos recogidos. La clave de esta técnica está en tomar las decisiones adecuadas a partir de estos análisis e interpretaciones. El objetivo que se persigue es optimizar las operaciones, alinear los recursos disponibles con las necesidades reales y mejorar la planificación de actividades de mantenimiento [9].

Además del ahorro de costes, común a todas las técnicas de mantenimiento predictivo, el monitoreo tiene otras ventajas. Ayuda a cumplir objetivos de sostenibilidad de las empresas mediante la reducción del consumo y el aumento de la eficiencia energética. Esto también impacta en la reducción de la huella ambiental mediante la prolongación de la vida útil de los componentes eléctricos. Por último, y no menos importante, aumenta la seguridad de los trabajadores al reducir los riesgos de fallos eléctricos y por tanto de los accidentes provocados por estos.

2.2.4 Fases del Mantenimiento Predictivo

El proceso de implementación del mantenimiento predictivo en un entorno industrial consta de varias fases que se suceden:

2.2.4.1 Monitoreo de condiciones

Mediante la instalación de sensores o equipos portátiles se recopilan los datos relevantes deseados de los activos. Los más frecuentes según su carácter son:

Parámetros mecánicos

- Vibraciones. Detectan desalineaciones, desequilibrios y desgastes en rodamientos y engranajes. Utilizado especialmente en motores, bombas, turbinas y compresores.
- Temperatura. Medición de sobrecalentamientos en motores eléctricos, cojinetes, rodamientos o transformadores. Se mide principalmente con sensores y cámaras termográficas.
- Alineación y desequilibrio: medidas usando análisis de vibraciones o herramientas laser.

Parámetros eléctricos

- Corriente y tensión eléctrica. Detección de sobrecargas, desequilibrios de fase o armónicos.
- Análisis de firma eléctrica. Detección de defectos mecánicos y eléctricos en motores eléctricos.

Parámetros de lubricación

Análisis de aceites. Se miden viscosidad, contaminación, presencia de partículas metálicas, oxidación...para prevenir desgastes internos, contaminación o degradación de los lubricantes.

Otros parámetros

- Flujos de presión y caudal. Medidos para detectar fugas, obstrucciones o fallos de bomba en sistemas neumáticos e hidráulicos.
- Ultrasonidos. Principalmente medidos para detectar fugas de aire o de gases, descargas eléctricas y problemas en válvulas y rodamientos.
- Velocidad de rotación. Para descartar el mal funcionamiento de motores y ejes.
- Análisis de gases. Medidos en motores de combustión o transformadores

Parámetros operacionales o de proceso

- Horas de operación y ciclos de trabajo.
- Paradas no programadas.
- Arranques forzados.
- Producción baja o pérdidas de eficiencia.

Parámetros medidos en sistemas HVAC

Categoría	Parámetro	Qué Detecta	Cómo se Mide
Mecánicos	Vibraciones	Desequilibrio, rodamientos dañados, desalineación	Acelerómetros, sensores de vibración
	Temperatura	Sobrecalentamiento en motores, compresores	Termopares, sensores IR, cámaras termográficas
	Ruido / Ultrasonido	Fugas de gas o aire, fallos en válvulas	Sensores ultrasónicos o acústicos
Eléctricos	Corriente y Voltaje	Sobrecargas, desequilibrio de fases, fallos de compresor	Pinzas amperimétricas, sensores eléctricos
	Factor de Potencia	Ineficiencia energética	Analizadores de red
	Firma Eléctrica (ESA)	Fallos en bobinados, desequilibrio, excentricidad	Equipos ESA especializados
Fluidos y Refrigerante	Presión del Refrigerante	Fugas o sobrepresión	Manómetros electrónicos
	Temperatura del Refrigerante	Subenfriamiento o sobrecalentamiento	Termopares o sensores RTD
	Nivel / Calidad del Aceite	Desgaste interno del compresor	Análisis de laboratorio o sensores in situ
Aire y Flujo	Caudal de Aire	Filtros sucios, fallos en ventiladores	Anemómetros, sensores de flujo
	Presión Diferencial en Filtros	Saturación de filtros	Sensores de presión diferencial
	Humedad / Temperatura Ambiente	Condiciones de confort, riesgo de condensación	Sensores integrados en BMS o termohigrómetros

Tabla 2.1: Variables habitualmente monitorizadas en sistemas de climatización para mantenimiento predictivo

2.2.4.2 Recogida, almacenamiento y transmisión de datos

Una vez que se definen los parámetros a medir se procede a su recogida. Puede ser continua (datos recogidos en tiempo real) o periódica (extracción de datos cada cierto tiempo con un intervalo definido).

Los datos se pueden almacenar en algún dispositivo local o transmitirse a un sistema en la nube, ya sea por cable o de forma inalámbrica.

2.2.4.3 Procesamiento y análisis de datos

Los datos recogidos se procesan mediante software especializado que tiene como objetivo eliminar datos que no sirvan y buscar patrones relevantes. Este análisis suele incluir creación de tendencias históricas y comparación con umbrales definidos de forma que nos permite entender el comportamiento del activo y poder predecir estados futuros.

2.2.4.4 Diagnostico

A partir del procesamiento de los datos recogidos se realiza un diagnostico que identifica posibles averías a través de comportamientos anómalos detectados a través de las variables monitoreadas.

El diagnostico no consiste solo en detectar que hay un problema, también revela la ubicación (componente) y la causa original. Un buen diagnostico permite evitar paradas no deseadas en la producción y planificar de forma más eficiente las paradas para mantenimiento.

2.2.4.5 Pronostico

El atractivo principal del mantenimiento predictivo es su capacidad para predecir el comportamiento futuro de los activos y los estados de sus componentes. En la fase de pronóstico se estima el RUL (Remaining Useful Life), es decir, el tiempo que queda antes de que ocurra una avería crítica.

Este pronóstico se basa en el desgaste observado y su comparación con los modelos ya existentes según los datos históricos del activo, que son proyectados en el tiempo hacia delante.

Tener una estimación precisa del RUL permite actuar antes de que haya una avería, pero con la suficiente precisión para que la intervención no sea demasiado prematura, de forma que se ahorren costes de mantenimiento evitando hacerlos cuando la pieza no tiene ningún comportamiento anómalo, como podría ocurrir con el mantenimiento preventivo por intervalos de tiempo

2.2.4.6 Planificación y toma de decisiones

Una vez hechos el diagnostico y el pronóstico, es hora de tomar las decisiones necesarias para planificar las acciones concretas de mantenimiento que se quieran llevar a cabo:

- Programación de reparación o reemplazo de componentes
- Asignación de recursos disponibles o de repuestos
- Reagendamiento del proceso de producción para evitar impactos por parada
- Revisión de las políticas de mantenimiento actuales

2.2.5 Ventajas del Mantenimiento Predictivo

Ya hemos nombrado varias de las ventajas del mantenimiento predictivo asociadas a las diferentes técnicas usadas. Ahora las repasamos todas:

Reducción de tiempos de parada no deseados

Al anticiparse al fallo de componentes, se pueden programar las paradas para mantenimiento en momentos adecuados, evitando paradas imprevistas o no deseadas que afectan a la producción y la eficiencia.

Extensión de la vida útil de activos y sus componentes

La detección de parámetros desviados de las curvas esperadas permite corregir a tiempo desgastes que se están desarrollando en algunos componentes o equipos y así prolongar su vida útil.

Disminución en los costes de mantenimiento

Al realizar el mantenimiento solo cuando es necesario y no antes, se eliminan costes asociados al exceso de mantenimiento preventivo cuando no es necesario, optimizando los recursos técnicos humanos y de repuestos de piezas.

Mejora en la planificación operativa

Al poder planificar y elegir las ventanas de mantenimiento, estas se pueden integrar con la planificación de la producción, de forma que no tengan impacto (o que el impacto sea mínimo) sobre esta última.

Aumento en la seguridad laboral

La reducción de fallos de componentes implica una reducción en la posibilidad de accidentes laborales que pueden afectar tanto a personas como al entorno de las propias fábricas.

Toma de decisiones empíricas

Gracias al uso de herramientas tecnológicas avanzadas se obtienen datos precisos, lo que permite tomar decisiones técnicas y estratégicas fiables.

Aumento en la fiabilidad

Cuando un sistema sigue un programa de monitoreo predictivo suele operar de manera más estable, lo que reduce la incertidumbre durante el funcionamiento.

Reducción del impacto ambiental

Evitar averías y optimizar los activos reduce las emisiones y la generación de residuos, mejorando la sostenibilidad de las operaciones.

2.2.6 Desventajas del Mantenimiento Predictivo

Aunque el mantenimiento predictivo ofrece muchas ventajas, su implementación también es un desafío y cuenta con varias limitaciones. Detallamos algunas de estas desventajas:

Coste inicial de implementación

El desembolso inicial es uno de los principales obstáculos para implementar un enfoque predictivo en el mantenimiento. Los sensores, dispositivos de monitoreo, sistemas de recogida y análisis de datos, y en algunos casos la necesidad de software especializado hacen que la inversión inicial alcance valores en ocasiones inabordables, especialmente para organizaciones o empresas de menor tamaño.

Conocimientos técnicos necesarios

Algunas partes del proceso como el análisis de datos, la interpretación de señales de condición o el uso de herramientas tecnológicas innovadoras como la inteligencia artificial o el machine learning requieren personal cualificado específicamente para estas tareas y procesos.

Dependencia de la calidad y fiabilidad de los datos

El éxito del mantenimiento predictivo pasa por la cantidad, calidad y consistencia de los datos que se recogen. Conjuntos de datos incompletos o con ruido reducen la fiabilidad de los pronósticos y pueden hacer que el proceso no sea rentable.

Contexto de aplicación

No todos los entornos industriales son adecuados para aplicar mantenimiento predictivo. En procesos de activos y componentes con ciclos de vida cortos o de baja criticidad implementar un sistema de mantenimiento preventivo no suele ser rentable.

Exceso de confianza en el sistema automatizado

A pesar de la fiabilidad del sistema, no se pueden descuidar fallos no detectables mediante sensores, para lo que se deben mantener las inspecciones visuales y otros tipos de controles tradicionales para detectar fallos de origen humano o estructural no detectables mediante el monitoreo.

Grandes volúmenes de información

La recolección continua de datos genera un volumen considerable, que se debe almacenar, gestionar y analizar de forma eficiente. Pueden ser necesarios sistemas informáticos complejos y costosos, así como buenas prácticas y una política clara de almacenamiento y mantenimiento de datos y ciberseguridad.

2.2.7 Conclusiones

Son activos críticos aquellos cuyas averías impactan directamente en la producción o la seguridad. Una parte significativa de las empresas industriales dispone de activos cuya indisponibilidad puede afectar de forma importante a la actividad productiva.

- Son medibles mediante sensores
- Pueden sufrir averías predecibles según manuales o datos históricos.
- Tienen valor económico o de criticidad suficiente como para justificar la implantación de mantenimiento predictivo

Diversos estudios indican una implantación creciente del mantenimiento predictivo en el ámbito industrial, especialmente en activos críticos cuya avería puede afectar significativamente a la producción, la eficiencia energética o la seguridad.

En conclusión, el mantenimiento predictivo representa una evolución significativa respecto a las estrategias tradicionales y se está afianzando como uno de los pilares clave en la industria 4.0.

Entre los activos industriales que más pueden beneficiarse de estas estrategias se encuentran los sistemas de climatización, debido a su elevado consumo energético, funcionamiento continuo y gran cantidad de variables susceptibles de monitorización. Por ello, en el siguiente capítulo se analizan sus principios de funcionamiento, componentes principales y parámetros de eficiencia más relevantes.

3 SISTEMAS DE CLIMATIZACIÓN

Los sistemas de climatización (en inglés, sistemas HVAC, Heating, Ventilation and Air Conditioning) se han convertido en elementos fundamentales en cualquier edificio, debido a su capacidad para garantizar tanto el confort térmico de sus ocupantes como la calidad del aire que respiran [13], [16].

En esencia, el proceso consiste en que la sección central del sistema de climatización calienta o enfría un fluido que a continuación es distribuido por las zonas objetivo. El sistema de distribución depende del refrigerante utilizado. Estos sistemas controlan no solo temperatura y humedad, sino otros parámetros como la calidad, la distribución y el retorno del aire. De esta forma, además de confort térmico, proporcionan una buena ventilación y renovación del aire, manteniendo su calidad.

En los entornos industriales, además de priorizar la comodidad del usuario, también está en juego la continuidad operativa del producto, la integridad de los activos o de algunos de sus componentes, así como la gestión eficiente de los consumibles empleados durante el proceso.

3.1. Mantenimiento predictivo en sistemas de climatización

Se ha elegido en este trabajo poner el foco teórico-práctico en los sistemas de climatización, ya que el mantenimiento predictivo resulta fundamental en ellos por varias razones críticas que exponemos a continuación.

Prevención de fallos críticos

Punto común a todos los sistemas bajo un sistema de mantenimiento predictivo, aunque en este caso hay motivos beneficiosos adicionales. Un fallo en climatización no solo afectaría al propio activo o a sus componentes, sino también al proceso productivo dentro de una fábrica, o a la comodidad y la salud de sus trabajadores, lo que puede originar problemas de mayor envergadura. Por ello, detener esta reacción en cadena antes de que se inicie puede ser un factor clave para el buen funcionamiento y la competitividad de la empresa.

Optimización del consumo energético

Como hemos visto en la introducción, los sistemas de climatización consumen buena parte del gasto energético total de un edificio industrial. Componentes en estado no óptimo, como filtros sucios, compresores deteriorados o válvulas obstruidas ayudan a que este consumo aumente por encima de lo necesario.

Mediante el mantenimiento predictivo, se pueden monitorear continuamente estos sistemas y detectar ineficiencias en tiempo real, manteniendo el sistema en un punto óptimo de funcionamiento a través de intervenciones adecuadamente programadas. También se reduce el coste técnico, ya que se interviene solo cuando es necesario y no antes, mientras se optimiza la vida útil de los componentes.

Calidad del aire en interior

Los sistemas de climatización con un mantenimiento bajo son susceptibles de acumular polvo, moho u otros contaminantes que afectan a la calidad del aire en interior (IAQ) debido a componentes como filtros, conductos o ventiladores.

Soporte de tecnologías inteligentes

Los sistemas de climatización modernos permiten la integración de sensores, sistemas IoT (Internet of Things) y plataformas BMS (Building Management System). Esto permite recoger datos en tiempo real, aplicar aprendizaje automático y análisis estadístico a los sistemas y automatizar decisiones de mantenimiento antes de que los efectos de una avería se puedan percibir.

3.2. Tipos de sistemas de climatización

Los sistemas de climatización se clasifican en dos grupos generales, unidades autónomas y sistemas centrales. Cada uno tiene sus propios métodos de operación, configuración y aplicaciones, dependiendo de las necesidades a cubrir en cada edificio o proceso industrial [13]. En el ámbito que tratamos en el trabajo, los entornos industriales, se pueden usar ambos tipos. La elección de un tipo u otro depende del tamaño del recinto, el tipo de proceso, las exigencias ambientales y la flexibilidad operativa.

3.2.1 Unidades autónomas (packaged units)

Los sistemas de este tipo convierten una fuente de energía primaria (normalmente electricidad o gas) de forma directa en calefacción o refrigeración para el entorno en el que actúan. Son fáciles de instalar, más frecuentes en edificios y oficinas pequeñas o zonas que requieren control térmico individual. Algunos ejemplos de este grupo son:

Sistemas de climatización en azoteas (Rooftop Units)

Las Rooftop Units (RTU) son unidades de climatización compactas propias de edificios comerciales. Se instalan en las azoteas y suministran aire acondicionado directamente al interior.

Precisamente una Rooftop Unit será el primero de los dos casos prácticos expuestos en el capítulo 5 de este trabajo, veremos su funcionamiento en detalle más adelante.

Acondicionadores de aire individuales

Son unidades de ventana o portátiles que enfrían espacios individuales

Bombas de calor aire-aire

Pueden enfriar y calentar, ya que tienen la capacidad de transferir calor entre el aire del exterior y del interior en cualquier dirección.

Un esquema típico de sistema de climatización autónomo es el de la siguiente imagen:




Figura 3.1: esquema típico de sistema de climatización autónomo

3.2.2 Sistemas centrales

Los sistemas centrales generan energía térmica en una ubicación principal y luego la distribuyen a las zonas objetivo mediante agua o aire. Se dividen a su vez en un subsistema de generación (calderas, bombas de calor centralizadas entre otros) y varios subsistemas terminales que acondicionan el aire en las diferentes zonas del edificio. La configuración más habitual suele incluir

Sistemas centrales de agua caliente y fría centralizados

Distribuyen agua, calentada o enfriada, a través de un sistema de tuberías hasta los subsistemas terminales.

Unidades fan coil (ventiloconvectores)

Utilizan intercambiadores de calor agua-aire (bobinas) para acondicionar el aire localmente.

En cuanto a los tipos más comunes de subsistemas terminales:

Sistemas de zona única

Cubren una única área con control uniforme

Sistemas multizona

Emplean cajas de volumen de aire variable (VAV) regulando el caudal de aire a cada zona, lo que permite un control de temperatura individual por zona.

Los sistemas centrales son más frecuentes en edificios de gran tamaño, ya que son más eficientes energéticamente, aunque conllevan una mayor complejidad en cuanto a control y mantenimiento [11], [12].

En la siguiente figura vemos un esquema típico de sistema central de climatización.




Figura 3.2: Estructura típica de un sistema de climatización central

Aire exterior (A)

El proceso comienza con la captación de aire exterior, necesario para garantizar la renovación del aire interior y poder mantener una buena calidad del aire (Internal Air Quality, IAQ). Este aire será tratado más adelante antes de distribuirlo a las zonas de destino final.

Torre de enfriamiento (B)

Están asociadas exclusivamente a los enfriadores enfriados por agua (no por aire). Disipan el calor del interior del edificio hacia el exterior. El agua caliente proveniente del condensador del enfriador se enfría en la torre por evaporación, de forma que el agua recirculada hacia el enfriador esté a menor temperatura.

Unidad de manejo de aire (C)

Es el núcleo donde se acondiciona el aire antes de su distribución (Air Handling Unit, AHU) y está formada por tres componentes principales

El filtro elimina las partículas contaminantes o no deseadas del aire exterior, el ventilador impulsa el aire limpio a través de todo el sistema, y las bobinas intercambiadoras de calor enfrían o calientan el aire. Las bobinas están conectadas tanto al enfriador como a la caldera.

Bombas (D)

Las bombas transportan agua caliente o fría (dependiendo si es desde el enfriador o desde la caldera) hacia las bobinas de la unidad de manejo de aire. Suele haber una bomba para cada circuito hidráulico independiente (caliente y frío)

Enfriador (E)

Se encarga generar agua fría mediante un ciclo de compresión de vapor. El líquido refrigerante absorbe calor del agua en el evaporador del enfriador y lo libera en el condensador (en la torre de enfriamiento (B)). Posteriormente el agua circula hacia la AHU para enfriar el aire. Normalmente, en el entorno industrial son utilizados los enfriadores enfriados por agua, debido a su mayor eficiencia y capacidad.

Zona objetivo (F)

La zona objetivo representa el espacio interior a climatizar. El aire tratado en la AHU se distribuye hacia estas zonas a través de los conductos. Parte del aire puede ser recirculado al sistema para su posterior reacondicionamiento.

Caldera (G)

Proporciona agua o vapor caliente para calentar la zona objetivo. La salida está conectada a las bobinas de calefacción en la AHU, lo que permite calentar el aire. También se usa para alimentar sistemas de calefacción interior como radiadores.

3.3. Componentes principales de los sistemas de climatización

Un sistema de climatización típico está compuesto por varios elementos que trabajan en conjunto para lograr el control de los parámetros ambientales deseados y que pueden ser objetivo de monitoreo y sensorización al estar sujetos a un entorno de mantenimiento predictivo [14], [15].

3.3.1 Unidad de calefacción (Heating)

Utiliza diferentes tipos de equipos con el objetivo de subir la temperatura durante las épocas más frías del año

Calderas

Utilizan diferentes tipos de combustible para calentar agua o producir vapor. El fluido calentado es distribuido a través de radiadores o redes de tuberías.

Bombas de calor

Mediante un ciclo de compresión, intercambian calor entre el interior y el exterior.

3.3.2 Unidad de enfriamiento (Air Conditioning)

Tiene como objetivos bajar la temperatura y controlar la humedad del aire durante los meses más calurosos. Sus componentes pueden variar según la configuración o el tipo de sistema que se elija, pero hay algunos principales y comunes a todos ellos.

Compresor

Comprime el refrigerante y permiten que circule por el sistema, hasta el condensador

Condensador

Convierten el refrigerante gaseoso a alta presión y temperatura en líquido, liberando el calor absorbido del aire interior del edificio hacia el exterior

Evaporadores

Extrae calor del interior del edificio, lo que provoca que el refrigerante cambie de líquido a gas, enfriando el aire que posteriormente será distribuido por el edificio para enfriar el ambiente.

Válvula de expansión

Regula la cantidad de refrigerante que entra al evaporador.

3.3.3 Sistema de ventilación (Ventilation)

Es la parte encargada de mantener el aire interior fresco y limpio, renovándolo constantemente y eliminando así contaminantes y malos olores. La ventilación puede ser natural, dependiendo de diferencias de presión y temperatura para mover el aire, o mecánica, utilizando ventiladores y conductos para manejar con más precisión la cantidad y la calidad del aire utilizado. Los principales componentes comunes que componen este sistema son:

Ventiladores

Mueven el aire por los conductos.

Conductos

Distribuyen el aire exterior (fresco) de la forma deseada por el interior.

Filtros de aire

Eliminan las partículas y contaminantes que contiene el aire exterior antes de que sea distribuido por el edificio

Intercambiadores de calor

En los casos en los que se esté utilizando el sistema de calefacción, retienen parte de la energía termina del aire interior que se extrae, reduciendo el coste energético.

3.3.4 Conductos y tuberías

Permiten distribuir el aire caliente o frío de manera uniforme por las distintas áreas objetivo. En entornos industriales, los más comunes son los conductos de chapa metálica, ya que son duraderos y versátiles.

3.3.5 Dispositivos de control

Monitorizan las instalaciones, fundamentales para garantizar una adecuada eficiencia energética y la seguridad operativa. Los principales son:

Termostato

Es el elemento principal de control de toda la instalación. Recibe señales de diferentes sensores y reacciona a ellas.

Sensores

Los de temperatura y humedad son los más comunes, pero también pueden ser de CO₂, presión o de caudal de aire o de agua (controladores de zona y válvulas de control). Recogen información que envían al termostato.

Actuadores

Accionan válvulas y conductos que regulan los flujos de aire y agua, dependiendo de las necesidades del sistema

3.4. Eficiencia energética en sistemas de climatización

La evaluación del rendimiento energético de los sistemas de climatización es fundamental para la selección de equipos eficientes y el diseño de instalaciones sostenibles, identificando oportunidades de ahorro y optimización [11], [12]. Esta evaluación se basa en una serie de indicadores que miden aspectos distintos del desempeño del sistema.

Los indicadores se pueden clasificar atendiendo a dos criterios principales: según el nivel de aplicación pueden ser indicadores de equipo o de instalación. Según la temporalidad de la medición pueden ser instantáneos o estacionales.

3.4.1 Indicadores de eficiencia instantáneos y estacionales

3.4.1.1 Indicadores de eficiencia instantaneos

Reflejan la eficiencia en un momento concreto, bajo condiciones de carga y de temperatura puntuales. Son indicados para el control operativo en tiempo real.

Coefficient of Performance (COP)

Coeficiente de rendimiento. Mide la eficiencia de un equipo cuando trabaja en ciclo de calefacción. Se define como la relación entre la potencia calorífica (energía útil aportada) y la potencia eléctrica consumida, ambas medidas bajo condiciones de prueba específicas y a plena carga.

$$COP = \frac{\text{Potencia calorífica de salida } (Q_{calor}, kW)}{\text{Potencia eléctrica de entrada } (P_{eléctrica}, kW)}$$

Energy Efficiency Ratio (EER)

Ratio de eficiencia energética. Mide la eficiencia de un equipo cuando trabaja en ciclo de refrigeración. Se define como la relación entre la potencia frigorífica (energía útil extraída) y la potencia eléctrica consumida, ambas medidas bajo condiciones de prueba específicas y a plena carga.

$$EER = \frac{\text{Potencia frigorífica de salida } (Q_{frío}, kW)}{\text{Potencia eléctrica de entrada } (P_{eléctrica}, kW)}$$

3.4.1.2 Indicadores de eficiencia estacionales

Los indicadores estacionales permiten evaluar el rendimiento energético de un sistema de climatización a lo largo de un periodo representativo de funcionamiento, considerando las variaciones de carga térmica, temperatura exterior y condiciones de operación que se producen durante una temporada completa. Por este motivo, proporcionan una visión más realista del comportamiento energético del equipo que los indicadores instantáneos [11], [12].

Seasonal Coefficient of Performance (SCOP)

El SCOP relaciona la energía térmica total aportada por el sistema durante una temporada de calefacción con la energía eléctrica consumida para ello. Este indicador tiene en cuenta las variaciones de temperatura exterior y las diferentes condiciones de carga a las que se enfrenta el equipo durante su funcionamiento real.

$$SCOP = \frac{\text{Energía calorífica de salida } (E_{calor}, kW)}{\text{Potencia eléctrica de entrada } (P_{eléctrica}, kW)}$$

Seasonal Energy Efficiency Ratio (SEER)

El SEER es el indicador utilizado para evaluar la eficiencia energética de un sistema de climatización en modo refrigeración durante toda una temporada de funcionamiento. Se define como la relación entre la energía frigorífica total suministrada por el equipo y la energía eléctrica consumida durante el mismo periodo.

$$SEER = \frac{\text{Energía frigorífica de salida } (E_{frío}, kW)}{\text{Potencia eléctrica de entrada } (E_{eléctrica}, kW)}$$

3.4.2. Sistemas de regulación inteligente

Son fundamentales en los sistemas de climatización modernos para mantener la eficiencia energética y el tiempo de vida útil de los componentes en rangos óptimos.

Termostatos inteligentes

Permiten ajustar la climatización de forma remota dando respuesta a valores en tiempo real de ocupación y condiciones ambientales de las zonas sobre las que actúan.

Sistemas de gestión de edificios

Los BMS (Building Management Systems) o BAS (Building Automation Systems) integran los sistemas HVAC con otros subsistemas, como iluminación o alarmas, para controlarlos de forma centralizada.

Control por zonas con VAV

Con el sistema VAV (Volumen de Aire Variable) se regula el flujo de aire según la demanda térmica de cada zona

Sistemas de ventilación con recuperación de calor

Aprovechan la energía del aire saliente para calentar la alimentación de aire tomada del exterior, reduciendo la demanda energética en calefacción.

3.4.3. Integración de energías renovables

Las energías solar, geotérmica (aprovecha la temperatura constante del subsuelo) y aerotérmica (extrae energía térmica del aire exterior), aplicadas a los sistemas HVAC, permiten reducir el consumo de energía convencional y por lo tanto los costes a largo plazo, disminuyendo la dependencia de combustibles fósiles.

4 REFRIGERACIÓN INDUSTRIAL

La refrigeración industrial desempeña un papel clave en numerosos procesos productivos, especialmente en la conservación de materias primas y productos sensibles a la temperatura.

En este contexto, los congeladores industriales son equipos diseñados para mantener condiciones térmicas constantes y muy por debajo de 0°C , garantizando tanto la calidad del producto como la continuidad del proceso.

4.1. Principios de la refrigeración industrial

Los congeladores industriales suelen operar bajo el ciclo de compresión de vapor, compuesto por cuatro elementos principales:

- Compresor: aspira el refrigerante en estado gaseoso a baja presión y lo comprime, aumentando su presión y temperatura.
- Condensador: intercambia calor con el ambiente, condensando el gas a líquido a alta presión.
- Válvula de expansión: reduce la presión del refrigerante líquido, preparándolo para evaporarse.
- Evaporador: permite la evaporación del refrigerante a baja presión, absorbiendo calor del interior del congelador y enfriando el espacio.




Figura 4.1: Ciclo de refrigeración industrial

La eficiencia de este ciclo se evalúa mediante indicadores como el Coeficiente de Rendimiento (COP), que relaciona la energía útil de refrigeración con la energía eléctrica consumida [11].

4.2. Funcionamiento de los congeladores industriales

Un congelador industrial mantiene temperaturas típicas entre -20°C y -50°C , dependiendo del producto y del proceso. Para garantizar estas condiciones, el sistema cuenta con sensores de temperatura, controladores electrónicos y ciclos programados de descongelación (defrost) para evitar la acumulación de hielo en el evaporador.

Las variables más importantes para la monitorización de su funcionamiento son: temperatura interna del congelador, tiempo de estabilización tras la apertura de puertas, frecuencia y duración de los ciclos de descongelación (desescarche) y consumo eléctrico.

4.3. Modos de fallo comunes

Los congeladores pueden presentar problemas operativos que afectan a la eficiencia y estabilidad térmica. Los observados más frecuentemente son:

- Fugas de refrigerante: reducen la capacidad de enfriamiento.
- Fallo en el sellado de puertas: aumenta la temperatura del interior del congelador y provoca la formación de escarcha.
- Obstrucción de evaporadores o condensadores: disminuye la transferencia de calor, se pierde capacidad de enfriamiento y aumenta el consumo eléctrico, reduciendo la eficiencia energética.
- Desescarche deficiente: genera acumulación de hielo, lo que reduce el flujo de aire frío.
- Fatiga del compresor: aumenta el consumo energético, reduciendo el rendimiento.

4.4. Mantenimiento predictivo en congeladores

El mantenimiento predictivo en este tipo de equipos se centra en el análisis continuo de variables como la temperatura, el consumo eléctrico o las presiones del sistema de refrigerante. Con datos de temperatura de alta frecuencia es posible:

- Detectar tendencias de deriva térmica (cambios progresivos y sostenidos de temperatura del sistema respecto a su punto de operación normal a lo largo del tiempo).

La deriva térmica suele indicar una degradación progresiva de una parte o componente del sistema, como suciedad en el condensador o el evaporador, fuga pequeña y lenta de refrigerante o pérdida de aislamiento o sellado en la puerta

- Identificar ciclos anómalos de desescarche
- Medir la estabilidad térmica a través de métricas adicionales como la desviación estándar o el tiempo fuera de rango

La implementación de técnicas de análisis de datos, tal como se describe en los capítulos posteriores, permite anticipar fallos potenciales, optimizar la eficiencia del sistema y garantizar la calidad del producto almacenado.

5 CASO PRÁCTICO 1 – ROOFTOP UNIT

En este apartado se presenta el desarrollo en la práctica de un sistema de mantenimiento predictivo mediante el uso de Python, que ya hemos presentado como una herramienta potente y accesible para este tipo de análisis.

Gracias a su variedad de bibliotecas, vamos a procesar y explorar los datos de un caso real, analizar su comportamiento energético y desarrollar posteriormente un modelo predictivo para la detección de estados degradados.

5.1. Conjunto de datos utilizado

Los datos que se van a usar pertenecen a una unidad de climatización industrial de tipo RTU (Rooftop Unit) sensorizada, a lo largo de un verano, situada en un entorno industrial real en el estado de Connecticut en Estados Unidos [15]. Los RTU son sistemas autónomos, muy utilizados en entornos comerciales e industriales (oficinas, centros comerciales, hospitales o naves logísticas) debido a su capacidad para gestionar refrigeración, ventilación y control de aire de forma integrada.

5.1.1. Variables registradas

Este conjunto de datos contiene lecturas registradas en intervalos regulares de tiempo durante el funcionamiento continuo de la unidad rooftop a lo largo de dos días diferentes de verano. Incluye variables que describen el comportamiento térmico, eléctrico, hidráulico y de control del sistema lo que nos permite hacer un análisis completo del estado operativo y detectar anomalías previas al fallo.

En la siguiente tabla tenemos una visión general de todas las variables recogidas por los sensores de la unidad rooftop y sus características.

Variable	Descripción	Nombre en la hoja de datos	Unidades
$Power_{main}$	Potencia de alimentación	MAIN	W
$Power_{fan}$	Potencia ventilador	FAN	W
$Power_{comp1}$	Potencia del compresor del circuito 1	COMP.A	W
$Power_{comp2}$	Potencia del compresor del circuito 2	COMP.B	W
P_{suc1}	Presión de aspiración del refrigerante del circuito 1	SUCP1	Bar
P_{suc2}	Presión de aspiración del refrigerante del circuito 2	SUCP2	Bar
T_{suc1}	Temperatura de aspiración del refrigerante del circuito 1	SUCT1	°C
T_{suc2}	Temperatura de aspiración del refrigerante del circuito 2	SUCT2	°C
P_{dis1}	Presión de descarga del refrigerante del circuito 1	DISP1	Bar
P_{dis2}	Presión de descarga del refrigerante del circuito 2	DISP2	Bar
T_{dis1}	Temperatura de descarga del refrigerante del circuito 1	DIST1	°C
T_{dis2}	Temperatura de descarga del refrigerante del circuito 2	DIST2	°C
T_{EL1}	Temperatura tras expansión circuito 1	EXT1	°C
T_{EL2}	Temperatura tras expansión circuito 2	EXT2	°C
AFR	Caudal de aire	FLW	CFM
$T_{air,cond}$	Temperatura del aire en la salida del condensador	CONT	°C
$T_{air,evap}$	Temperatura del aire en la salida del evaporador	EVAT	°C
$T_{air,econ}$	Temperatura del aire en el economizador	ECT	°C
$RH_{air,econ}$	Humedad relativa en el economizador	ECRH	%
$T_{air,ret}$	Temperatura del aire de retorno	RET	°C
$T_{air,ret,avg}$	Temperatura media del aire de retorno	RUAVG	°C
$RH_{air,ret}$	Humedad relativa en el aire de retorno	RERH	%
$T_{air,sup}$	Temperatura del aire de impulsión	SUT	°C
$RH_{air,sup}$	Humedad relativa del aire de impulsión	SURH	%
$T_{air,sup,avg}$	Temperatura media del aire de entrada	SUAVG	°C
$RH_{air,sup,avg}$	Humedad relativa media del aire de entrada	SUAVG.Humidity	%
$T_{air,i}$	Temperatura del aire interior	IT	°C
$RH_{air,ret,avg}$	Humedad media del aire de retorno	RUAVG.Humidity	%
$T_{air,o}$	Temperatura del aire exterior	OT	°C
$RH_{air,o}$	Humedad relativa del aire exterior	ORH	%

Tabla 5.1: Variables objetivo recogidas por los sensores integrados en la RTU

Uno de los motivos de elegir este conjunto de datos es que las variables son especialmente relevantes para técnicas de FDD (Fault, Detection and Diagnosis) [16] y mantenimiento predictivo, pudiendo detectar casos como:

- Fallos en compresores
- Obstrucciones en válvulas
- Problemas de flujo de aire o refrigerante
- Pérdida de eficiencia del ciclo frigorífico
- Desviaciones térmicas o presiones anómalas

A continuación se puede ver el esquema de la unidad rooftop con las localizaciones de los sensores con los que se han recogido los datos de las principales variables:




Figura 5.1: Esquema de la unidad Rooftop y sus principales variables

La figura 5.1 muestra la ubicación de las principales variables relacionadas con el circuito de aire de la unidad rooftop. Entre ellas hay algunas que resultan especialmente relevantes en este bloque:

- ECT: temperatura del aire de mezcla. representa las condiciones de entrada al evaporador y refleja la actuación del economizador sobre la corriente de aire tratada.
- EVAT: temperatura a la salida del evaporador.
- SUT: temperatura del aire de impulsión o suministro.
- MAIN, FAN, COMP y COMP.B: potencias eléctricas requeridas por el sistema completo, el ventilador de suministro y los compresores de ambos circuitos frigoríficos, respectivamente.

5.1.2. Formato y carga del conjunto de datos

El conjunto de datos está recogido en un archivo Excel, lo que facilita su integración con herramientas de análisis en Python. El conjunto incluye una columna temporal que indica el instante de cada registro, permitiendo tratar la información como una serie temporal, lo que resulta fundamental para el análisis de tendencias, ciclos de operación y evolución progresiva del estado del sistema.

La variable temporal “TIME” se convierte al formato “datetime” de Python para facilitar su tratamiento cronológico y la representación temporal de los datos. Posteriormente se realiza una inspección inicial del conjunto de datos para verificar el tipo de las variables y detectar posibles valores ausentes o inconsistencias.

```
import pandas as pd

# Carga de las dos jornadas
dia1 = pd.read_excel("RTU dataset.xlsx", sheet_name=2)
dia2 = pd.read_excel("RTU dataset.xlsx", sheet_name=3)

# Conversión de la columna temporal
dia1['TIME'] = pd.to_datetime(dia1['TIME'])
dia2['TIME'] = pd.to_datetime(dia2['TIME'])

# Inspección inicial
print("Día 1")
dia1.info()

print("\nDía 2")
dia2.info()
```

```
Día 1
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1428 entries, 0 to 1427
Data columns (total 32 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Count                 1428 non-null  int64
1   TIME                 1428 non-null  datetime64[ns]
2   RUAVG                1428 non-null  float64
3   FAN                  1428 non-null  float64
4   COMP                 1428 non-null  float64
5   MAIN                 1428 non-null  float64
6   FLW                  1428 non-null  float64
7   ECRH                 1428 non-null  float64
8   ORH                  1428 non-null  float64
9   RERH                 1428 non-null  float64
10  SURH                 1428 non-null  float64
11  SUAVG                1428 non-null  float64
12  ECT                  1428 non-null  float64
13  OT                   1428 non-null  float64
14  IT                   1428 non-null  float64
15  RET                  1428 non-null  float64
16  SUT                  1428 non-null  float64
17  DISP2               1428 non-null  float64
18  DISP1               1428 non-null  float64
19  SUCP2               1428 non-null  float64
20  SUCP1               1428 non-null  float64
21  CONT                1428 non-null  float64
22  EVAT                1428 non-null  float64
23  EXT2                1428 non-null  float64
24  EXT1                1428 non-null  float64
25  SUCT2               1428 non-null  float64
26  SUCT1               1428 non-null  float64
27  DIST2               1428 non-null  float64
28  DIST1               1428 non-null  float64
29  COMP.B              1428 non-null  float64
30  SUAVG.Humidity      1428 non-null  float64
31  RUAVG.Humidity      1428 non-null  float64
dtypes: datetime64[ns](1), float64(30), int64(1)
memory usage: 357.1 KB
```

```
Día 2
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1428 entries, 0 to 1427
Data columns (total 32 columns):
#   Column                Non-Null Count  Dtype
---  -
0   Count                 1428 non-null  int64
1   TIME                 1428 non-null  datetime64[ns]
2   RUAVG                1428 non-null  float64
3   FAN                  1428 non-null  float64
4   COMP                 1428 non-null  float64
5   MAIN                 1428 non-null  float64
6   FLW                  1428 non-null  float64
7   ECRH                 1428 non-null  float64
8   ORH                  1428 non-null  float64
9   RERH                 1428 non-null  float64
10  SURH                 1428 non-null  float64
11  SUAVG                1428 non-null  float64
12  ECT                  1428 non-null  float64
13  OT                   1428 non-null  float64
14  IT                   1428 non-null  float64
15  RET                  1428 non-null  float64
16  SUT                  1428 non-null  float64
17  DISP2               1428 non-null  float64
18  DISP1               1428 non-null  float64
19  SUCP2               1428 non-null  float64
20  SUCP1               1428 non-null  float64
21  CONT                1428 non-null  float64
22  EVAT                1428 non-null  float64
23  EXT2                1428 non-null  float64
24  EXT1                1428 non-null  float64
25  SUCT2               1428 non-null  float64
26  SUCT1               1428 non-null  float64
27  DIST2               1428 non-null  float64
28  DIST1               1428 non-null  float64
29  COMP.B              1428 non-null  float64
30  SUAVG.Humidity      1428 non-null  float64
31  RUAVG.Humidity      1428 non-null  float64
dtypes: datetime64[ns](1), float64(30), int64(1)
memory usage: 357.1 KB
```

Figura 5.2: información general sobre variables del conjunto de datos

5.1.3. Descripción estadística inicial

Antes de realizar el análisis energético se lleva a cabo una inspección estadística preliminar de las principales variables registradas. Para ello se calculan parámetros descriptivos básicos como el valor medio, mínimo, máximo y desviación estándar de las variables más relevantes para el funcionamiento de la unidad rooftop.

Este análisis permite obtener una primera visión de las condiciones de operación registradas en cada una de las jornadas estudiadas y detectar posibles diferencias entre ellas. Entre las variables seleccionadas se incluyen las principales magnitudes eléctricas (potencia total, ventilador y compresores), el caudal de aire tratado y las temperaturas características del proceso de climatización.

```
variables = ["MAIN", "FAN", "COMP", "COMP.B", "FLW", "OT", "RET", "ECT", "EVAT", "SUT", "IT"]

for nombre, df in [("DÍA 1", dia1), ("DÍA 2", dia2)]:
    print(nombre)
    display(df[variables].describe().T[["mean", "min", "max", "std"]].round(2))
```

DÍA 1		mean	min	max	std	DÍA 2		mean	min	max	std
	MAIN	7122.93	0.00	14315.00	4045.04		MAIN	6660.73	0.00	14914.00	3948.20
	FAN	1317.40	0.00	2345.00	703.89		FAN	1317.70	0.00	2367.00	704.47
	COMP	3700.45	0.00	7085.00	2017.85		COMP	3410.71	0.00	6577.00	1841.79
	COMP.B	1305.77	0.00	3779.00	1180.22		COMP.B	1189.86	0.00	4855.00	1504.40
	FLW	2255.40	33.66	3420.57	1172.96		FLW	2179.54	33.90	3448.16	1133.53
	OT	16.20	11.58	21.57	3.11		OT	24.36	20.78	28.67	2.41
	RET	24.82	22.66	28.72	2.00		RET	23.08	21.42	24.19	0.57
	ECT	25.47	22.00	29.90	2.40		ECT	23.48	21.20	25.91	1.22
	EVAT	16.24	11.38	25.96	4.74		EVAT	14.13	10.77	23.24	4.55
	SUT	19.35	15.25	25.24	3.03		SUT	16.94	12.81	24.45	3.81
	IT	25.34	23.37	28.11	1.62		IT	24.00	23.07	24.84	0.56

Figura 5.3: Descripciones estadísticas de ambos días del conjunto de datos

Este análisis proporciona información sobre máximos y mínimos, medias, desviaciones estándar y rangos de variación. En este caso ha revelado comportamientos esperados, como:

- Temperaturas de impulsión (SUT) generalmente menores que las de retorno (RET) en modo refrigeración.
- Caudales (FLW) con variabilidad asociada al estado del ventilador (FAN).
- Humedades relativas entre 30% y 80%, dentro de los rangos esperados para confort térmico.
- Las variables de consumo eléctrico muestran patrones cíclicos, concordantes con la activación de compresores y ventiladores

El objetivo de este análisis no consiste en extraer conclusiones definitivas, sino proporcionar una primera validación del conjunto de datos y sentar las bases para las etapas de preprocesamiento, ingeniería de características y análisis exploratorio que se desarrollan a continuación.

5.2. Preparación y tratamiento de los datos

El preprocesamiento de los datos es una etapa fundamental en cualquier proyecto de mantenimiento predictivo, ya que garantiza que los modelos trabajen con información coherente, limpia y útil. En sistemas industriales reales, los datos procedentes de sensores pueden contener valores inconsistentes, registros incompletos o magnitudes expresadas en unidades no homogéneas, lo que hace imprescindible esta etapa.

En este trabajo, el conjunto de datos disponible está formado por dos jornadas de funcionamiento de una unidad rooftop registradas en fechas diferentes. Antes de realizar el análisis energético y predictivo, es necesario identificar las variables disponibles, verificar la calidad de los registros y preparar el conjunto de datos para los cálculos posteriores.

5.2.1. Variables registradas y significado físico

El conjunto de datos utilizado contiene un número elevado de variables que describen distintos aspectos del funcionamiento de la unidad Rooftop. Estas variables se agrupan en función de su significado físico y de su relación con los principales procesos del sistema de climatización.

- Variables térmicas del aire. Permiten caracterizar el proceso de enfriamiento y deshumidificación llevado a cabo en el evaporador y por tanto evaluar el intercambio térmico real del sistema mediante las cargas sensible y latente.
- Variables de caudal y ventilación. Describen el volumen de aire manejado por la unidad en cada instante. Condicionan directamente la capacidad de intercambio térmico del evaporador y afectan al rendimiento energético y al confort térmico proporcionado.
- Variables eléctricas. Recogen el consumo de potencia del sistema. Permiten cuantificar el esfuerzo energético necesario para mantener las condiciones de operación y constituyen la base para el cálculo de indicadores de eficiencia como el EER y el SEER. En el contexto del mantenimiento predictivo, incrementos anómalos en el consumo eléctrico suelen estar asociados a degradación de componentes y funcionamiento fuera de condiciones óptimas.
- Variables de estado y control. Indican el modo de funcionamiento del sistema y permiten identificar periodos de operación activa y parada. Son esenciales para interpretar correctamente el resto de magnitudes medidas y para evitar la inclusión de registros no representativos en los análisis posteriores.
- Variables de estado del refrigerante. Presión y temperatura en distintos puntos de los circuitos frigoríficos. Permiten evaluar las condiciones de evaporación y condensación del refrigerante, así como detectar posibles desviaciones respecto al funcionamiento esperado del ciclo frigorífico.

5.2.2. Preprocesamiento inicial del conjunto de datos

Una vez identificadas y clasificadas las variables del conjunto, se procede a realizar un preprocesamiento inicial para comprobar la coherencia física del conjunto de datos y adecuarlo para los cálculos energéticos posteriores.

Homogeneización de unidades

El caudal de aire se proporciona en el conjunto de datos en unidades CFM, por lo que se necesita su conversión a m^3/h (unidad utilizada habitualmente para climatización en España) para garantizar coherencia dimensional en los cálculos térmicos posteriores.

```
# Conversión de caudal de aire de CFM a m3/h
df['airflow_m3h'] = df['FLW'] * 1.699
```

5.2.3. Ingeniería de características orientada a la eficiencia energética

En esta fase del procesamiento se lleva a cabo un proceso de ingeniería de características con el objetivo de completar el conjunto de datos original generando nuevas variables físicas derivadas de las existentes. Se busca estimar la eficiencia energética real del sistema de climatización durante su funcionamiento en régimen de refrigeración a partir de las variables medidas por los sensores en la unidad rooftop.

Tal y como se expuso en el capítulo 3, la eficiencia de un sistema de climatización en modo refrigeración puede evaluarse mediante indicadores como el EER y el SEER, que relacionan la potencia térmica extraída del aire y la potencia eléctrica consumida para ello. Dado que el conjunto de datos no aporta directamente la potencia frigorífica del sistema, vamos a estimarla a partir de las condiciones termodinámicas del aire antes y después del evaporador.

Para ello, se va a calcular la potencia térmica total intercambiada en el evaporador, compuesta por sus componentes sensible y latente. Se van a generar columnas nuevas a integrar en el conjunto inicial de datos y que serán usadas en los análisis posteriores, permitiéndonos calcular el EER instantáneo y posteriormente el SEER como indicador global de eficiencia energética.

Evaluación de la eficiencia mediante el indicador SEER

El indicador SEER permite evaluar el rendimiento energético global de un sistema de climatización a lo largo de un periodo representativo de operación, teniendo en cuenta los diferentes estados de carga y ambientales que puede atravesar. Esto hace que proporcione una visión mucho más completa que la del EER, al estar este último basado en condiciones instantáneas.

El SEER se define como la relación entre la energía térmica total intercambiada y la potencia eléctrica consumida por el sistema en el mismo periodo

$$SEER = \frac{\Sigma Q_{total}}{\Sigma P_{eléctrica}}$$

En nuestro caso, la energía térmica total intercambiada (Q_{total}) es el calor extraído del aire de mezcla al pasar por el evaporador. La potencia eléctrica es la consumida por los compresores y ventiladores de todo el sistema, dato que nos viene dado en el conjunto.

Calculo del EER instantáneo

Como ya se ha definido antes en este trabajo, el EER es un indicador instantáneo que relaciona la potencia térmica extraída del aire con la potencia eléctrica consumida por el sistema en ese mismo instante.

$$EER = \frac{Q_{total}}{P_{eléctrica}}$$

Se va a calcular el EER para cada registro temporal del conjunto de datos, incorporándolo como una columna nueva. Esta magnitud permite analizar la evolución temporal de la eficiencia del sistema, y es la base para calcular posteriormente el SEER por agregación temporal.

Para obtener el EER, se necesita estimar la potencia térmica total (Q_{total}) intercambiada en el evaporador a partir de nuestro conjunto de datos.

Potencia total intercambiada en el evaporador

Mientras la Rooftop está en ciclo de refrigeración, el evaporador extrae potencia calorífica del aire mediante dos mecanismos simultáneos: el enfriamiento del aire (carga sensible) y la reducción de su humedad (carga latente). La potencia térmica total intercambiada se define como la suma de ambas.

$$Q_{total} = Q_{sensible} + Q_{latente}$$

Este enfoque es adecuado en sistemas de climatización cuando trabajan en ciclo de refrigeración, ya que la deshumidificación representa una parte significativa de la potencia térmica total extraída.

Cálculo de la carga térmica sensible

La carga térmica sensible está asociada a la disminución de temperatura del aire al atravesar el evaporador. Para su cálculo se define primero la diferencia entre las temperaturas del aire antes y después de este.

Para este cálculo se utiliza la temperatura de impulsión (SUT), aunque se vea afectada por el calentamiento del ventilador, ya que la temperatura tras el evaporador (EVAT) no representa de forma correcta la temperatura promedio del aire al salir de los evaporadores.

$$\Delta T = ECT - SUT$$

```
# Definición de incremento de temperatura en el evaporador
df['delta_T'] = df['ECT'] - df['SUT']
```

A partir de esta diferencia, la carga térmica sensible instantánea se calcula mediante la expresión:

$$Q_{sensible} = \frac{0,335}{1000} \cdot V_{aire} \cdot \Delta T$$

```
# Definición de calor sensible
df['Q_sensible'] = (0.335 / 1000) * df['airflow_m3h'] * df['delta_T']
```

Donde V_{aire} es el caudal volumétrico de aire (m^3/h). La constante 0,335 agrupa la densidad del aire y su calor específico en condiciones estándar.

En el conjunto de datos, el caudal de aire corresponde a la variable FLW, que viene dado en unidades CFM (Cubic Feet per Minute, pies cúbicos por minuto). Por ello, antes de aplicar la ecuación, es necesario convertir esta unidad al SI mediante siguiente relación, que ya se aplicó en el código en el apartado de homogeneización de unidades.

$$1 \text{ CFM} = 1,699 \text{ m}^3/h$$

Cálculo de la carga térmica latente y deshumidificación del aire

Además del enfriamiento sensible, en el evaporador se reduce el contenido de humedad del aire, fenómeno que da lugar a la carga térmica latente. Para cuantificarla es necesario trabajar con la humedad absoluta del aire, expresada en gramos de vapor de agua por kilogramo de aire seco (gr/kg a.s.).

La humedad absoluta no se mide directamente en el sistema, pero se puede calcular a partir de la temperatura del aire y la humedad relativa mediante relaciones psicrométricas, para lo que se usará en este trabajo la librería de Python “psychrolib”.

```
# Instalación de la librería psychrolib
!pip install psychrolib
```

En el conjunto de datos disponemos de las siguientes variables:

- ECRH y ECT: humedad relativa y temperatura antes del evaporador (aire de mezcla).
- SURH y SUT: humedad relativa y temperatura después del evaporador (aire de alimentación)

A partir de estas variables se calcula la humedad absoluta en ambos puntos del sistema y se define la diferencia de humedad como:

$$\Delta\omega = \omega_{aire\ mezcla} - \omega_{alimentación}$$

```
from psychrolib import SetUnitSystem, SI
import psychrolib as psy

SetUnitSystem(SI)
pressure = 101325 # Presión atmosférica estándar

df['w_econ'] = df.apply(
    lambda r: psy.GetHumRatioFromRelHum(
        r['ECT'],
        r['ECRH'] / 100,
        pressure
    ),
    axis=1
)

df['w_supply'] = df.apply(
    lambda r: psy.GetHumRatioFromRelHum(
        r['SUT'],
        r['SURH'] / 100,
        pressure
    ),
    axis=1
)

df['delta_w'] = (df['w_econ'] - df['w_supply']) * 1000
```

La carga térmica latente se determina mediante la expresión:

$$Q_{latente} = \frac{0,833}{1000} \cdot V_{aire} \cdot \Delta\omega$$

```
# Definición y cálculo de calor latente
df['Q_latente'] = (0.833 / 1000) * df['airflow_m3h'] * df['delta_h']
```

La constante 0,833 agrupa el calor latente de vaporización del agua y los factores de conversión para trabajar con caudal volumétrico y humedad específica.

Cálculo del EER y del SEER

Una vez calculadas las cargas térmicas sensible y latente, se obtiene la potencia total intercambiada en el evaporador y se calcula el EER para cada registro temporal del conjunto de datos.

En este trabajo, el EER no se emplea únicamente como indicador de eficiencia energética, sino como una variable de diagnóstico operativo. Al relacionar potencia térmica útil intercambiada en el evaporador y potencia eléctrica consumida, cualquier degradación física del equipo podrá ser detectada al manifestarse como reducción progresiva del EER.

A partir de esta variable, el SEER se calcula como una magnitud agregada sobre el periodo de estudio, lo que nos permite evaluar el rendimiento energético global de la Rooftop. Con el SEER podemos analizar posibles descensos en la eficiencia y condiciones de funcionamiento anómalas asociadas a necesidades de mantenimiento.

```
# Conversión de la potencia eléctrica a kW
df['MAIN_kw'] = df['MAIN'] / 1000

# Cálculo del EER para cada instante
df['Q_total'] = df['Q_sensible'] + df['Q_latente']
df['EER_inst'] = df['Q_total'] / df['MAIN_kw']

SEER = df['Q_total'].sum() / df['MAIN_kw'].sum()
SEER
```

El valor obtenido para el SEER es 4. Esto indica que, durante el periodo bajo análisis, el sistema ha intercambiado aproximadamente 4 unidades de energía térmica por cada unidad de energía eléctrica consumida.

Este valor se sitúa dentro de un rango razonable para unidades de climatización industrial en condiciones de refrigeración en verano, lo que valida la coherencia del modelo implementado.

$$SEER = 4,008$$

Las variables adicionales obtenidas en este apartado se integrarán en el conjunto de datos de cara a utilizarlas en el análisis exploratorio, la simulación de fallos y el modelado predictivo desarrollado en los apartados siguientes.

5.3. Análisis exploratorio de datos (EDA)

Una vez preparado el conjunto de datos y generadas las variables calculadas asociadas a la eficiencia energética del sistema, se lleva a cabo un análisis exploratorio de datos (EDA). El objetivo es comprender el comportamiento operativo de la unidad rooftop y detectar patrones relevantes que puedan estar relacionados con pérdidas de eficiencia o condiciones anómalas de funcionamiento del sistema.

5.3.1. Comportamiento operativo general del sistema

Evolución temporal de las potencias eléctricas

Como primer paso, se analiza el comportamiento general del sistema a lo largo del tiempo mediante el consumo eléctrico de los principales componentes (ventiladores y compresores). Se representan la potencia eléctrica total consumida por la unidad (MAIN), la potencia asociada al ventilador (FAN) y las potencias demandadas por los dos compresores frigoríficos (COMP y COMP.B)

```

import matplotlib.pyplot as plt
import matplotlib.dates as mdates

# Configuración general
plt.rcParams["figure.figsize"] = (15,5)
plt.rcParams["font.size"] = 11

def formato_horas(ax):
    ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
    ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

def grafica_potencias(df, titulo):

    fig, ax = plt.subplots(figsize=(16,5))

    ax.plot(df["TIME"], df["MAIN"], label="MAIN")
    ax.plot(df["TIME"], df["FAN"], label="FAN")
    ax.plot(df["TIME"], df["COMP"], label="COMP")
    ax.plot(df["TIME"], df["COMP.B"], label="COMP.B")

    ax.set_title(titulo)
    ax.set_xlabel("Hora")
    ax.set_ylabel("Potencia (W)")

    formato_horas(ax)

    ax.grid(alpha=0.3)
    ax.legend()

    plt.tight_layout()
    plt.show()

# Potencias
grafica_potencias(dia1,"Evolución temporal de las potencias eléctricas - Día 1")
grafica_potencias(dia2,"Evolución temporal de las potencias eléctricas - Día 2")

```




Figura 5.4: Evolución temporal de las potencias eléctricas del día 1




Figura 5.5: Evolución temporal de las potencias eléctricas del día 2

En ambas jornadas se observa un comportamiento operativo muy similar. La unidad permanece parada durante las horas nocturnas y comienza su funcionamiento poco después de las 04:00 horas, lo que provoca un incremento brusco del consumo eléctrico asociado al ventilador y al primer compresor.

Durante el periodo de funcionamiento, la potencia total evoluciona de forma paralela a la demanda frigorífica de la instalación. El consumo del ventilador se mantiene constante durante toda la jornada, mientras que los compresores modulan su funcionamiento en función de las necesidades térmicas del sistema.

Se observan varias maniobras de control que provocan variaciones puntuales en la potencia eléctrica. Estas transiciones corresponden a cambios en el estado de los compresores y forman parte del comportamiento habitual de este tipo de sistemas de climatización.

Ambas jornadas presentan perfiles eléctricos muy similares, sin apreciarse diferencias significativas en la secuencia de arranque, funcionamiento y parada de la unidad.

Evolución temporal de las temperaturas principales

De forma similar, se representan las temperaturas principales del sistema. Concretamente, se muestran la temperatura exterior (OT), la temperatura de retorno del recinto (RET), la temperatura de entrada al evaporador (ECT), la temperatura de salida del evaporador (EVAT), la temperatura de impulsión (SUT) y la temperatura del interior del edificio (IT)

```
def grafica_temperaturas(df, titulo):

    fig, ax = plt.subplots(figsize=(16,5))

    ax.plot(df["TIME"], df["OT"], label="OT")
    ax.plot(df["TIME"], df["RET"], label="RET")
    ax.plot(df["TIME"], df["ECT"], label="ECT")
    ax.plot(df["TIME"], df["EVAT"], label="EVAT")
    ax.plot(df["TIME"], df["SUT"], label="SUT")
    ax.plot(df["TIME"], df["IT"], label="IT")

    ax.set_title(titulo)
    ax.set_xlabel("Hora")
    ax.set_ylabel("Temperatura (°C)")

    formato_horas(ax)

    ax.grid(alpha=0.3)
    ax.legend()

    plt.tight_layout()
    plt.show()

# Temperaturas
grafica_temperaturas(dia1,"Evolución temporal de las temperaturas principales - Día 1")
grafica_temperaturas(dia2,"Evolución temporal de las temperaturas principales - Día 2")
```




Figura 5.6: Evolución temporal de las temperaturas el día 1




Figura 5.7: Evolución temporal de las temperaturas el día 2

A diferencia de lo observado en las variables eléctricas, las condiciones térmicas de ambas jornadas presentan diferencias significativas.

Durante el día 1, la temperatura exterior oscila entre 12°C y 21°C, manteniéndose durante gran parte del día claramente por debajo de la temperatura del aire de retorno. Esta situación genera una diferencia térmica considerable entre las condiciones exteriores y las condiciones interiores de la instalación.

Además, a pesar de tener una temperatura exterior considerablemente baja que podría invitar a funcionar aumentando significativamente la proporción de aire exterior y reduciendo la necesidad de refrigeración mecánica en algunos tramos del día, se observa que la temperatura en el economizador (ECT) es prácticamente idéntica a la temperatura de retorno (RET), lo que invita a pensar que el economizador no está funcionando en el día 1, bien por avería o bien por decisión de cara a analizar el comportamiento del sistema sin recirculación.

Por el contrario, la segunda jornada se desarrolla bajo condiciones climáticas más cálidas, con temperaturas exteriores comprendidas aproximadamente entre 21°C y 29°C. En este caso, la temperatura exterior presenta valores más próximos e incluso superiores durante buena parte del día.

También se aprecia que las temperaturas características del proceso de climatización presentan una evolución más homogénea durante la segunda jornada. Las variaciones observadas son más suaves y las relaciones entre las distintas temperaturas resultan más estables a lo largo del tiempo.

En el día 2 también se puede observar que ocurre un fenómeno atípico. La diferencia entre la temperatura

de salida del evaporador (EVAT) y la temperatura de impulsión (SUT) es del orden de 5°C, un valor demasiado elevado, hasta que se pone en marcha el segundo compresor y se reduce a unos 2°C, un orden de magnitud más típico para esta diferencia. Debido a esto se podría considerar que el sensor que mide esta temperatura se podría estar viendo afectado por el aire caliente acumulado en la cámara tras el evaporador del circuito 2, cuando el segundo compresor no está funcionando.

Estas diferencias indican que ambas jornadas corresponden a condiciones operativas claramente distintas, especialmente desde el punto de vista térmico, a pesar de presentar perfiles eléctricos muy similares.

Selección de la jornada de estudio

Aunque ambas jornadas muestran patrones eléctricos comparables, las condiciones térmicas registradas son significativamente diferentes. La primera jornada se caracteriza por temperaturas exteriores considerablemente inferiores a las temperaturas interiores del recinto, mientras que la segunda jornada presenta condiciones climáticas más exigentes y próximas a las que habitualmente afronta la instalación durante los periodos de mayor demanda de refrigeración.

Además la segunda jornada muestra un comportamiento térmico más estable, lo que facilita la interpretación física de los indicadores energéticos calculados en los apartados posteriores.

Por estos motivos, y con el fin de trabajar sobre un conjunto de datos representativo y coherente desde el punto de vista operativo, el resto del análisis desarrollado en este capítulo se realizará exclusivamente utilizando los registros correspondientes a la segunda jornada de medida.

```
df = dia2.copy()
```

Una vez que tenemos cargado exclusivamente el día 2 en Python, tenemos que volver a calcular todas las variables calculadas en el apartado 5.2.3 (ingeniería de características), ya que se calcularon sobre el conjunto de los dos días.

```
# Conversión de caudal
df['airflow_m3h'] = df['FLW'] * 1.699

# Calor sensible
df['delta_T'] = df['ECT'] - df['SUT']
df['Q_sensible'] = (0.335 / 1000) * df['airflow_m3h'] * df['delta_T']

# Humedad absoluta
from psychrolib import SetUnitSystem, SI
import psychrolib as psy

SetUnitSystem(SI)
pressure = 101325

df['w_econ'] = df.apply(lambda r: psy.GetHumRatioFromRelHum(r['ECT'], r['ECRH']/100, pressure), axis=1)
df['w_supply'] = df.apply(lambda r: psy.GetHumRatioFromRelHum(r['SUT'], r['SURH']/100, pressure), axis=1)

df['delta_w'] = (df['w_econ'] - df['w_supply']) * 1000

# Calor latente
df['Q_latente'] = (0.833 / 1000) * df['airflow_m3h'] * df['delta_w']

# Potencia frigorífica total
df['Q_total'] = df['Q_sensible'] + df['Q_latente']

# EER
df['MAIN_kw'] = df['MAIN'] / 1000
df['EER_inst'] = df['Q_total'] / df['MAIN_kw']
```

5.3.2. Evolución temporal del caudal de aire

Para estos cálculos, se han limpiado previamente los datos, quitando todos aquellos valores en los que el ventilador y el compresor 1 están apagados, ya que podrían introducir ruido en forma de valores físicamente incoherentes a los cálculos.

```
df = df[(df["FAN"] > 0) & (df["COMP"] > 0)].copy()
```

El caudal de aire manejado por la unidad condiciona directamente la capacidad de intercambio térmico del evaporador, influyendo tanto en la potencia térmica estimada como en los indicadores de eficiencia energética del sistema.

A continuación, se analiza su evolución temporal con el objetivo de identificar posibles cambios en el régimen de ventilación y contextualizar el comportamiento energético de la unidad durante el periodo estudiado. Además, se representa el valor medio del caudal de aire para facilitar la interpretación del régimen de funcionamiento predominante




Figura 5.8: Evolución temporal del flujo de aire en el evaporador

La línea discontinua representa el caudal medio de aire durante el periodo analizado ($4715 \text{ m}^3/\text{h}$), permitiendo comparar las variaciones instantáneas respecto al régimen medio de funcionamiento del sistema.

5.3.3. Evolución temporal del EER

Una vez seleccionada la segunda jornada de estudio y calculadas las variables energéticas derivadas, se analiza la evolución temporal del coeficiente EER.

```
import numpy as np

df["EER_inst"] = df["Q_total"] / df["MAIN_kw"]
df["EER_inst"] = df["EER_inst"].replace([np.inf, -np.inf], np.nan)

eer_medio = df["EER_inst"].mean()

fig, ax = plt.subplots(figsize=(16,4))

ax.plot(df["TIME"], df["EER_inst"], label="EER instantáneo")

ax.axhline(eer_medio, color="red", linestyle="--", linewidth=2, label=f"EER medio = {eer_medio:.2f}")

ax.set_title("Evolución temporal del EER instantáneo - Día 2")
ax.set_xlabel("Hora")
ax.set_ylabel("EER")

ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.9: Evolución temporal del EER instantáneo del sistema

Los resultados muestran un comportamiento estable del EER durante la mayor parte del periodo analizado. El valor medio obtenido es de 3,53.

Se observan pequeñas oscilaciones asociadas a cambios en las condiciones de funcionamiento de la unidad, especialmente durante los periodos de arranque, maniobras de control y transiciones entre estados operativos. Sin embargo estas variaciones son de corta duración y no afectan apenas a la tendencia general del sistema.

No se aprecia una separación clara entre diferentes etapas asociadas a la activación de uno o dos compresores. Esto indica que el incremento de capacidad frigorífica aportado por la segunda etapa de compresión viene acompañado de un aumento aproximadamente proporcional del consumo eléctrico, manteniéndose la relación entre potencia útil y potencia consumida relativamente constante.

5.3.4. Distribución estadística del EER

Para caracterizar el comportamiento habitual del sistema desde el punto de vista energético, se analiza la distribución estadística del EER mediante un histograma de frecuencias. Esto permite definir el rango típico de eficiencia del sistema e identificar valores atípicos característicos de condiciones anómalas, si los hubiera.

```
fig, ax = plt.subplots(figsize=(8,4))

ax.hist(df['EER_inst'].dropna(), bins=30)

eer_medio = df['EER_inst'].mean()

ax.axvline(eer_medio,
            color='red',
            linestyle='--',
            linewidth=2,
            label=f'EER medio = {eer_medio:.2f}')

ax.set_title('Distribución del EER instantáneo')
ax.set_xlabel('EER')
ax.set_ylabel('Frecuencia')

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.10: Distribución estadística (histograma) del EER de la unidad rooftop

Esta distribución de valores es coherente con la que se observa en la evolución temporal del EER representada anteriormente. Concentración en torno al valor medio (3,53) sin apreciarse diferencias significativas que se puedan asociar a los diferentes modos de funcionamiento (uno o dos compresores activos).

Influencia de las etapas de compresión sobre la eficiencia energética

Con el objetivo de analizar la influencia del régimen de operación sobre la eficiencia energética del sistema, se ha realizado una comparación entre los periodos de funcionamiento con un único compresor activo y aquellos en los que ambos compresores operan simultáneamente.

Para cada caso se han calculado los valores medios de potencia eléctrica consumida, potencia térmica total intercambiada y eficiencia energética instantánea (EER). Esta comparación permite evaluar si el incremento de capacidad frigorífica asociado a la activación del segundo compresor se traduce en una mejora proporcional del rendimiento energético del sistema.

```
# Régimen con un solo compresor
df_1comp = df[(df["COMP"] > 0) & (df["COMP.B"] == 0)]

# Régimen con dos compresores
df_2comp = df[(df["COMP"] > 0) & (df["COMP.B"] > 0)]

# Tabla resumen
resumen = pd.DataFrame({"MAIN medio (W)": [
    df_1comp["MAIN"].mean(),
    df_2comp["MAIN"].mean()
],
    "Potencia térmica media (kW)": [
    df_1comp["Q_total"].mean(),
    df_2comp["Q_total"].mean()
],
    "EER medio": [
    df_1comp["EER_inst"].mean(),
    df_2comp["EER_inst"].mean()
]
}, index=["1 compresor", "2 compresores"])

# Redondear
resumen = resumen.round(2)

# Mostrar
display(resumen)
```

	MAIN medio (W)	Potencia térmica media (kW)	EER medio
1 compresor	6622.92	23.44	3.53
2 compresores	10506.26	37.08	3.53

Figura 5.11: Tabla comparativa de los regímenes de 1 y 2 compresores

Los resultados muestran que la activación del segundo compresor incrementa de forma proporcional la potencia eléctrica consumida y la potencia térmica intercambiada por el evaporador. Esto concuerda con los resultados del EER, cuyo valor medio apenas se ve afectado por el cambio de etapa de compresión, exceptuando arranques y transiciones.

5.3.5. Relación entre eficiencia, temperatura exterior y condiciones de evaporación

La temperatura exterior constituye uno de los factores más importantes que condicionan el rendimiento energético de una unidad de climatización. En sistemas de expansión directa, el aumento de la temperatura ambiente incrementa la carga térmica que debe absorber el evaporador y modifica las condiciones de funcionamiento del ciclo frigorífico, afectando directamente a la eficiencia energética del equipo.

Con el objetivo de analizar esta influencia, se estudia la relación entre el EER instantáneo y la temperatura exterior.

```
fig, ax = plt.subplots(figsize=(8,5))

df_1comp = df[df["COMP.B"] == 0]
df_2comp = df[df["COMP.B"] > 0]

ax.scatter(df_1comp["OT"], df_1comp["EER_inst"],
           label="1 compresor", alpha=0.7)

ax.scatter(df_2comp["OT"], df_2comp["EER_inst"],
           label="2 compresores", alpha=0.7)

ax.set_title("Relación entre EER y temperatura exterior - Día 2")
ax.set_xlabel("Temperatura exterior OT (°C)")
ax.set_ylabel("EER instantáneo")

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.12: Relación entre EER y temperatura exterior del aire

Una vez más observamos que la eficiencia permanece dentro de un rango estable a lo largo de todo el rango de temperaturas exteriores registrado. La mayor parte de los valores de EER se concentran en torno a 3,5, independientemente de que la unidad opere con una o dos etapas de compresión.

La unidad está adaptando adecuadamente su capacidad frigorífica a las variaciones de carga térmica mediante la activación del segundo circuito de compresión. Los pocos valores alejados de la tendencia principal corresponden a situaciones transitorias de corta duración asociadas a arranques, paradas o cambios de estado del sistema.

Fracción de aire exterior

Una de las variables responsables de la variación del EER es la proporción de aire exterior introducida mediante el economizador. El economizador es un sistema que utiliza el aire exterior para ahorrar energía cuando las condiciones lo permiten. En función de lo frío y seco que esté el aire exterior en comparación con el interior, el economizador abre unas compuertas que lo dejan pasar, pudiendo así reducir o apagar por completo los compresores del sistema.

Podemos calcular esta proporción en cada momento mediante variables de nuestro conjunto de datos, según la relación:

$$F_{AE} = \frac{T_{AM} - T_{AR}}{T_{AE} - T_{AR}}$$

Donde:

- T_{AM} es la temperatura del aire de mezcla (ECT en el conjunto de datos)
- T_{AE} es la temperatura del aire exterior (OT en el conjunto de datos)
- T_{AR} es la temperatura del aire de retorno (RET en el conjunto de datos)

Por tanto, en términos de las variables del conjunto de datos:

$$F_{AE} = \frac{ECT - RET}{OT - RET}$$

Si F_{AE} es igual a 0, significa que no está entrando aire del exterior y que todo el aire es de retorno. Cuando toma el valor 1, el sistema solo utiliza aire exterior para climatizar y expulsa todo el aire de retorno hacia el exterior. Aunque normalmente nunca debe ser 0, ya que existen leyes que establecen un mínimo de aire exterior obligatorio según la calidad de aire interior requerida.

A continuación se calcula esta relación y se representa su evolución en función de la temperatura exterior. Debido a la sensibilidad de esta expresión cuando las temperaturas del aire exterior y del aire de retorno presentan valores similares, los resultados obtenidos deben interpretarse de forma cualitativa. No obstante, permiten identificar tendencias generales de funcionamiento del economizador.

Previamente se hace un filtrado de valores que tengan sentido físico, eliminando aquellos que por algún motivo se encuentren fuera del rango entre 0 y 1.

```
# Cálculo de la fracción de aire exterior usando ECT como temperatura de mezcla
df["Frac_AE"] = (df["ECT"] - df["RET"]) / (df["OT"] - df["RET"])

# Filtrado de valores físicamente posibles
df_frac = df[(df["Frac_AE"] >= 0) & (df["Frac_AE"] <= 1)].copy()

print(f"Registros totales: {len(df)}")
print(f"Registros válidos: {len(df_frac)}")

# Representación
fig, ax = plt.subplots(figsize=(8,5))

ax.scatter(df_frac["OT"], df_frac["Frac_AE"], alpha=0.5)

ax.set_title("Fracción de aire exterior frente a temperatura exterior - Día 2")
ax.set_xlabel("Temperatura exterior OT (°C)")
ax.set_ylabel("Fracción de aire exterior")

ax.grid(True, alpha=0.3)

plt.tight_layout()
plt.show()
```

En el resultado hay 1111 registros totales de los cuales se han eliminado 38 que no entraban entre 0 y 1.




Figura 5.13: Relación entre fracción de aire exterior y temperatura exterior

Los resultados sugieren la existencia de una estrategia de control del aire exterior dependiente de la temperatura ambiente. Se observa un aumento significativo de la fracción de aire exterior para temperaturas comprendidas entre 23°C y 25°C, alcanzándose valores próximos a la ventilación con aire exterior total en determinados instantes. Para temperaturas superiores, la fracción de aire exterior disminuye y se mantiene en niveles relativamente constantes.

A continuación se representa la evolución temporal de la fracción de aire

```
fig, ax = plt.subplots(figsize=(16,4))

ax.plot(df_frac["TIME"], df_frac["Frac_AE"])

ax.set_title("Evolución temporal de la fracción de aire exterior - Día 2")
ax.set_xlabel("Hora")
ax.set_ylabel("Fracción de aire exterior")

ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

ax.grid(True, alpha=0.3)

plt.tight_layout()
plt.show()
```




Figura 5.14: Evolución temporal de la fracción de aire exterior

Se observa que durante la mayor parte de la jornada la fracción de aire se mantiene relativamente estable, pero se identifican periodos concretos en los que aumenta notablemente, llegando a alcanzar valores de casi el 100% de aire exterior.

Este comportamiento resulta consistente con la actuación de una estrategia de economización basada en aire exterior, cuando las condiciones ambientales son favorables, la unidad incrementa la apertura de las compuertas de aire exterior para aprovechar directamente el potencial de refrigeración disponible en el ambiente reduciendo así la potencia eléctrica necesaria y por tanto el coste económico.

Los resultados obtenidos constituyen una evidencia consistente de la actuación del economizador y permiten explicar parte de las variaciones observadas previamente en los indicadores de eficiencia energética del sistema.

Temperatura del aire de mezcla

Con el fin de validar la hipótesis utilizada para el cálculo de la fracción de aire exterior, se analiza la evolución temporal de la temperatura de entrada al evaporador (ECT), comparándola con la temperatura exterior (OT) y la temperatura de retorno del edificio (RET).

```
fig, ax = plt.subplots(figsize=(16,4))

ax.plot(df["TIME"], df["ECT"], label="ECT (aire de mezcla)")
ax.plot(df["TIME"], df["RET"], label="RET (retorno)")
ax.plot(df["TIME"], df["OT"], label="OT (exterior)")

ax.set_title("Evolución temporal de la temperatura del aire de mezcla - Día 2")
ax.set_xlabel("Hora")
ax.set_ylabel("Temperatura (°C)")

ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.15: Evolución temporal de las temperaturas ECT, RET y OT

Para completar el análisis, se representa el EER en función de la temperatura del aire de mezcla ECT.

```
fig, ax = plt.subplots(figsize=(8,5))

ax.scatter(df["ECT"], df["EER_inst"], alpha=0.5)

ax.set_title("Relación entre EER y temperatura del aire de mezcla - Día 2")
ax.set_xlabel("Temperatura del aire de mezcla ECT (°C)")
ax.set_ylabel("EER instantáneo")

ax.grid(True, alpha=0.3)

plt.tight_layout()
plt.show()
```




Figura 5.16: Relación entre EER y temperatura del aire de mezcla

Aunque existe cierta dispersión en el intervalo entre 23,5°C y 24,5°C no se observa una tendencia clara de aumento o disminución de la eficiencia en función de la temperatura del aire de mezcla.

Este comportamiento sugiere que las variaciones de la temperatura del aire de mezcla modifican la carga térmica instantánea que debe asumir el sistema, pero la regulación de la unidad permite compensar dichas variaciones.

Aunque la temperatura del aire de mezcla resulta una variable fundamental para caracterizar las condiciones de operación del evaporador y la actuación del economizador, su influencia sobre la eficiencia energética global del sistema resulta limitada dentro del rango de condiciones analizado.

5.3.6. Análisis de las cargas térmicas sensible y latente

La potencia térmica total intercambiada en el evaporador tiene dos componentes diferenciados: la carga térmica sensible, asociada al enfriamiento del aire, y la carga térmica latente, asociada al proceso de deshumidificación. El análisis conjunto de ambos resulta fundamental para comprender el comportamiento energético real del sistema y para interpretar correctamente los valores obtenidos de eficiencia energética.

Evolución temporal de las cargas térmicas sensible y latente

En primer lugar, se analiza la evolución temporal de ambas cargas térmicas a lo largo del periodo de muestras. Esta representación permite identificar como varía el peso relativo de cada componente en función de las condiciones de operación del sistema.

```
fig, ax = plt.subplots(figsize=(16,4))

ax.plot(df["TIME"], df["Q_sensible"], label="Q sensible")
ax.plot(df["TIME"], df["Q_latente"], label="Q latente")

ax.set_title("Evolución temporal de las cargas térmicas - Día 2")
ax.set_xlabel("Hora")
ax.set_ylabel("Potencia térmica (kW)")

ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.17: Evolución temporal de las cargas latente y sensible

Las cargas sensible y latente presentan valores cercanos, siendo la latente superior durante la mayor parte del día. Este comportamiento es algo a tener en cuenta, ya que típicamente la carga sensible suele representar en torno al 60%-70% de la carga total, es decir, debería ser mayor que la latente.

Esto se debe a que la temperatura utilizada para calcular la carga sensible es la de impulsión (SUT) y no la de la salida del evaporador (EVAT), lo que provoca que en los cálculos se incluya la pérdida de temperatura que sufre el aire al pasar por el ventilador de impulsión y luego por el conducto hasta la zona acondicionada.

Relación entre cargas sensible y latente: Factor de Calor Sensible (FCS)

Con el objetivo de cuantificar de forma más precisa la contribución relativa de la carga térmica sensible y la carga térmica latente a la potencia total intercambiada en el evaporador, se introduce el parámetro FCS: Factor de Calor Sensible

Este factor se define como la relación entre la carga sensible y la carga térmica total

$$FCS = \frac{Q_{sensible}}{Q_{sensible} + Q_{latente}}$$

El FCS permite interpretar el peso relativo de cada componente del intercambio térmico. Cuanto mayor el valor del FCS, mayor es el peso del componente sensible (correspondiente a la temperatura).

Este indicador resulta especialmente útil en sistemas de climatización que operan en régimen de refrigeración, ya que permite interpretar si el esfuerzo del evaporador se concentra principalmente en reducir la temperatura del aire o en eliminar la humedad de éste.

A partir de las cargas térmicas calculadas anteriormente, se obtiene el valor del FCS para cada registro temporal del conjunto de datos, lo que permite analizar su evolución a lo largo del periodo de funcionamiento y caracterizar el comportamiento global del sistema desde el punto de vista psicrométrico.

Una vez calculados los valores instantáneos y el promedio, se representa el FCS a lo largo del tiempo, de la misma forma que se hizo con las cargas latente y sensible anteriormente

```

shf_medio = df["SHF"].mean()

fig, ax = plt.subplots(figsize=(16,4))

ax.plot(df["TIME"], df["SHF"], label="SHF")

ax.axhline(
    shf_medio,
    color="red",
    linestyle="--",
    linewidth=2,
    label=f"SHF medio = {shf_medio:.2f}"
)

ax.set_title("Evolución temporal del SHF - Día 2")
ax.set_xlabel("Hora")
ax.set_ylabel("SHF")

ax.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax.xaxis.set_major_locator(mdates.HourLocator(interval=2))

ax.grid(True, alpha=0.3)
ax.legend()

plt.tight_layout()
plt.show()

```




Figura 5.18: Evolución temporal del factor de calor sensible (FCS)

El valor medio obtenido de FCS es de 0,45, lo que indica que la carga latente tiene más peso que la sensible en la potencia térmica total. Lo habitual es que la carga necesaria para bajar la temperatura del aire sea superior a la necesaria para reducir su humedad. Sin embargo, en este caso se está incorporando a la carga sensible el calentamiento a través del ventilador y el conducto de impulsión, lo que reduce el incremento de temperatura utilizado para los cálculos.

La evolución temporal del FCS muestra además que la contribución relativa de las cargas sensible y latente permanece estable durante la mayor parte de la jornada, comportamiento coherente con las condiciones de operación observadas.

Evolución conjunta de cargas térmicas, potencia y EER

Para interpretar de forma más directa la evolución del rendimiento energético, se representa conjuntamente la potencia térmica total intercambiada en el evaporador, el consumo eléctrico de los compresores y el EER instantáneo. Esta representación resulta especialmente útil porque el EER se define como la relación entre la potencia térmica útil y la potencia eléctrica consumida.

De este modo, es posible observar si los aumentos de consumo eléctrico asociados a la activación de los compresores se traducen en incrementos proporcionales de la potencia térmica intercambiada, o si por el contrario dan lugar a reducciones del rendimiento energético instantáneo.

```
fig, ax1 = plt.subplots(figsize=(16,5))

# Potencia térmica total
ax1.plot(df["TIME"], df["Q_total"], label="Q total", linewidth=1.5)
ax1.set_xlabel("Hora")
ax1.set_ylabel("Potencia térmica Q total (kW)")

# Potencia de compresores
df["COMP_total_kW"] = (df["COMP"] + df["COMP.B"]) / 1000
ax1.plot(df["TIME"], df["COMP_total_kW"], label="Potencia compresores", linewidth=1.5)

# Segundo eje para EER
ax2 = ax1.twinx()
ax2.plot(df["TIME"], df["EER_inst"], color="green", label="EER instantáneo", linewidth=1.5, linestyle="--")
ax2.set_ylabel("EER")

# Formato eje X
ax1.xaxis.set_major_formatter(mdates.DateFormatter("%H:%M"))
ax1.xaxis.set_major_locator(mdates.HourLocator(interval=2))

# Leyenda conjunta
lineas1, etiquetas1 = ax1.get_legend_handles_labels()
lineas2, etiquetas2 = ax2.get_legend_handles_labels()
ax1.legend(lineas1 + lineas2, etiquetas1 + etiquetas2, loc="upper right")

ax1.set_title("Evolución conjunta de Q total, potencia de compresores y EER - Día 2")
ax1.grid(True, alpha=0.3)

plt.tight_layout()
plt.show()
```




Figura 5.19: evolución conjunta de la carga térmica total, potencia de compresión y EER

En naranja se representa el consumo de los compresores, en azul el calor total intercambiado y en verde el EER. Esta representación conjunta nos permite ver la relación directa existente entre la demanda térmica del sistema y su rendimiento energético.

Se observa que los incrementos de potencia eléctrica asociados a la activación de la segunda etapa de compresión vienen acompañados por aumentos similares de potencia térmica total intercambiada. Como consecuencia, el EER permanece relativamente constante durante la mayor parte de la jornada.

Este comportamiento indica que la unidad adapta su capacidad frigorífica a las necesidades térmicas del sistema sin experimentar pérdidas apreciables de eficiencia energética. La activación de etapas adicionales de compresión permite aumentar la capacidad de refrigeración disponible cuando la carga térmica lo requiere, manteniendo una relación prácticamente constante entre energía útil y energía consumida.

5.3.7. Dependencia entre variables principales

Como cierre del análisis exploratorio, se estudia la dependencia entre las principales variables operativas y energéticas del sistema mediante el cálculo de la matriz de correlación. Este análisis permite identificar relaciones lineales entre magnitudes relevantes y proporciona una visión global de cómo interactúan las variables que inciden directamente en la eficiencia energética del sistema.

Se ha optado por seleccionar únicamente variables con significado físico directo en el funcionamiento de la unidad rooftop. EER, potencia térmica total intercambiada, potencia eléctrica consumida, fracción de aire exterior, temperatura de entrada al evaporador y la temperatura exterior. De esta forma se evita incluir variables relacionadas entre sí, cuya correlación sería elevada por definición y no aportaría información adicional relevante.

```

# Selección de variables principales para la matriz de correlación
vars_corr = [
    'EER_inst',
    'Q_total',
    'MAIN',
    'Frac_AE',
    'ECT',
    'OT'
]

# Cálculo de la matriz de correlación
corr_matrix = df[vars_corr].corr()

```

Para una sencilla interpretación visual, la matriz de correlación se representa mediante un mapa de calor, utilizando la librería ‘seaborn’ de Python.

```

# Representación gráfica
import seaborn as sns
import matplotlib.pyplot as plt

fig, ax = plt.subplots(figsize=(7, 6))

sns.heatmap(
    corr_matrix,
    annot=True,
    fmt=".2f",
    cmap="coolwarm",
    center=0,
    square=True,
    linewidths=0.5,
    ax=ax
)

ax.set_title('Matriz de correlación entre variables energéticas y operativas')

plt.tight_layout()
plt.show()

```




Figura 5.20: Matriz de correlación de las variables principales

Los resultados permiten identificar las relaciones más relevantes entre eficiencia, carga térmica, consumo eléctrico y condiciones de entrada al evaporador. La correlación entre la potencia térmica total intercambiada y la potencia eléctrica consumida refleja que cuando aumenta la demanda frigorífica, el sistema requiere una mayor aportación eléctrica por la entrada en funcionamiento de la segunda etapa de compresión.

El EER presenta una relación inversa con el consumo eléctrico, lo que indica que los periodos de mayor potencia consumida no siempre se traducen en un aumento proporcional de la potencia térmica útil.

Por otro lado, la fracción de aire exterior y la temperatura de entrada al evaporador permiten interpretar la actuación del economizador. Las variaciones en la proporción de aire exterior modifican las condiciones térmicas del aire de mezcla y, por tanto, la carga que debe asumir el evaporador.

En conjunto, la matriz confirma que el comportamiento energético de la unidad rooftop no depende de una única variable, sino de la interacción entre carga térmica, consumo eléctrico y estrategia de ventilación. Este análisis sirve como base para la posterior selección de variables en la simulación de fallos y en el modelo predictivo.

5.4. Simulación de fallos

Una vez caracterizado el comportamiento del sistema en condiciones normales, se procede a la simulación de fallos con el objetivo de generar escenarios de funcionamiento degradado. Estos escenarios permiten analizar cómo se ven afectadas las principales magnitudes energéticas del sistema y constituyen la base para el desarrollo posterior de modelos de mantenimiento predictivo.

Dado que el conjunto de datos disponible no incluye etiquetas explícitas de fallo, la simulación se realiza introduciendo degradaciones controladas sobre variables con significado físico, representativas de fallos habituales en unidades Rooftop.

5.4.1. Enfoque de la simulación de fallos

La simulación de fallos se basa en los siguientes principios:

- Los fallos deben tener significado físico.
- Su efecto debe reflejarse en variables energéticas fundamentales.
- La degradación debe ser progresiva.
- El sistema debe seguir siendo realista

En este trabajo, los fallos se van a introducir modificando indirectamente la eficiencia del sistema a través de:

- Reducción de la potencia térmica intercambiada
- Reducción del caudal de aire
- Degradación del EER instantáneo

5.4.2. Selección de fallos simulados

Se consideran tres tipos de fallo en el sistema de climatización.

1. Ensuciamiento del intercambiador de calor (evaporador)
2. Pérdida de caudal de aire
3. Degradación del rendimiento del compresor

Estos fallos afectan directamente a la eficiencia energética del sistema y son habituales en equipos que operan de forma ininterrumpida.

Los fallos se simularán con la ayuda de una variable llamada ‘degradation’ en nuestro código que representará un factor de degradación progresiva de un 20% en la magnitud en la que se incide en cada caso.

5.4.3. Simulación de ensuciamiento del evaporador

El ensuciamiento del evaporador reduce la capacidad de intercambio térmico, provocando una disminución progresiva de la potencia térmica intercambiada para un mismo consumo eléctrico.

Implementación de la degradación

Se simula este fallo introduciendo una reducción progresiva de la potencia térmica

```
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.dates as mdates

df_fault = df.copy()
df_fault['MAIN_kw'] = df_fault['MAIN'] / 1000
degradation = np.linspace(0, 0.20, len(df_fault))
df_fault['Q_total_foul'] = df_fault['Q_total'] * (1 - degradation)
df_fault['EER_foul'] = df_fault['Q_total_foul'] / df_fault['MAIN_kw']
```

Comparación del EER

Esta disminución incide sobre el EER, que se representa a continuación comparándolo con el real que ya se representó anteriormente

```
fig, ax = plt.subplots(figsize=(15, 4))

ax.plot(df['TIME'], df['EER_inst'], label='EER normal')

ax.plot(df_fault['TIME'], df_fault['EER_foul'], '--', label='EER con ensuciamiento')

ax.set_title('Simulación de ensuciamiento del evaporador')
ax.set_xlabel('Hora')
ax.set_ylabel('EER')

ax.xaxis.set_major_formatter(mdates.DateFormatter('%H:%M'))

ax.grid(True)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.21: comparativa entre EER en condiciones normales y con el evaporador sucio

Con esta simulación se representa un deterioro progresivo del rendimiento del sistema, típico de equipos con mantenimiento deficiente.

5.4.4. Simulación de pérdida de caudal de aire

Una reducción en el caudal de aire puede deberse a filtros obstruidos o problemas en el ventilador, afectando principalmente a la carga térmica sensible

Implementación de la degradación

Se simula este fallo introduciendo una reducción progresiva del caudal de aire.

```
df_fault['airflow_foul'] = df_fault['airflow_m3h'] * (1 - degradation)

df_fault['Q_sensible_air'] = (0.335 / 1000) * df_fault['airflow_foul'] * df_fault['delta_T']

df_fault['Q_latente_air'] = (0.833 / 1000) * df_fault['airflow_foul'] * df_fault['delta_w']

df_fault['Q_total_air'] = df_fault['Q_sensible_air'] + df_fault['Q_latente_air']

df_fault['EER_air'] = df_fault['Q_total_air'] / df_fault['MAIN_kw']
```

Comparación del EER

Se representa la comparación del EER con una disminución en el flujo de aire en el evaporador:

```
fig, ax = plt.subplots(figsize=(15, 4))

ax.plot(df['TIME'], df['EER_inst'], label='EER normal')

ax.plot(df_fault['TIME'], df_fault['EER_air'], '--', label='EER con pérdida de caudal')

ax.set_title('Simulación de pérdida de caudal de aire')
ax.set_xlabel('Hora')
ax.set_ylabel('EER')

ax.xaxis.set_major_formatter(mdates.DateFormatter('%H:%M'))

ax.grid(True)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.22: comparativa entre EER tras disminución del flujo de aire en el evaporador

Se observa un efecto de disminución en el EER similar al de la reducción de la potencia térmica intercambiada.

5.4.5. Simulación de degradación del compresor

La degradación del compresor se manifiesta como un aumento del consumo eléctrico para una misma potencia intercambiada. Esto puede ser causado comúnmente por desgaste mecánico progresivo, falta de lubricación o sobrecalentamiento.

Implementación de la degradación

Se simula este fallo introduciendo un aumento progresivo de la potencia consumida por el compresor:

```
df_fault['MAIN_comp_foul'] = df_fault['MAIN_kw'] * (1 + degradation)

df_fault['EER_comp'] = df_fault['Q_total'] / df_fault['MAIN_comp_foul']
```

Comparación del EER

```
fig, ax = plt.subplots(figsize=(15, 4))

ax.plot(df['TIME'], df['EER_inst'],
        label='EER normal')

ax.plot(df_fault['TIME'], df_fault['EER_comp'],
        '--',
        label='EER con degradación del compresor')

ax.set_title('Simulación de degradación del compresor')
ax.set_xlabel('Hora')
ax.set_ylabel('EER')

ax.xaxis.set_major_formatter(mdates.DateFormatter('%H:%M'))

ax.grid(True)
ax.legend()

plt.tight_layout()
plt.show()
```




Figura 5.23: comparativa entre EER con degradación de comportamiento en el compresor

Aunque en un entorno real la degradación del compresor puede manifestarse de forma no progresiva (pudiendo depender de múltiples factores operativos), la introducción de un factor de degradación progresiva permite modelar el comportamiento típico de envejecimiento gradual del equipo

5.4.6. Generación de etiquetas de fallo

A partir de los escenarios simulados, se pueden generar etiquetas que indiquen el estado del sistema, sabiendo cuando su eficiencia esta fuera de rango de valores normales de eficiencia, facilitando la detección de fallos en fases tempranas.

```
df_fault['fault_label'] = 0
df_fault.loc[degradation > 0.1, 'fault_label'] = 1
```

Estas etiquetas permiten distinguir entre funcionamiento normal y funcionamiento degradado, sirviendo como variable objetivo en los modelos de aprendizaje automático.

Conclusión

La simulación de fallos desarrollada en este apartado permite generar escenarios realistas de degradación de la unidad Rooftop a partir de datos reales de operación registrados por sensores. El análisis del impacto de estos fallos sobre variables energéticas clave, como el EER, proporciona una base sólida para el desarrollo de modelos de mantenimiento predictivo.

5.5 Modelado predictivo en Python

Una vez caracterizado el comportamiento operativo y energético del sistema en condiciones normales, y generados escenarios de funcionamiento degradado mediante simulación de fallos, se procede al desarrollo de un modelo predictivo orientado a la detección automática de estados de degradación en la unidad RTU.

El objetivo de este apartado es evaluar la capacidad de técnicas de aprendizaje automático para identificar patrones asociados a fallos incipientes a partir de variables operativas y energéticas obtenidas del sistema.

5.5.1 Objetivo del modelado predictivo

El objetivo no es directamente predecir un fallo físico concreto (como una avería mecánica), sino que sea capaz de identificar desviaciones progresivas respecto al comportamiento normal del sistema.

Para ello, se plantea un modelo que sea capaz de clasificar cada instante de operación dentro de un estado de funcionamiento normal o funcionamiento degradado.

Esta aproximación resulta adecuada en entornos industriales reales, donde los fallos suelen desarrollarse de forma gradual y no siempre se dispone de información explícita sobre su naturaleza exacta.

En un entorno industrial real, este tipo de modelos pueden integrarse en sistemas de gestión de edificios (BMS) o en plataformas de gestión del mantenimiento asistido por ordenador (GMAO), activando órdenes de inspección cuando la probabilidad de estado degradado supere un umbral previamente definido. De esta forma, el modelo actúa como herramienta de apoyo para la toma de decisiones basada en datos.

5.5.2. Definición del problema y variable objetivo

El problema se formula como una tarea de clasificación supervisada, en la que el modelo aprende a partir de ejemplos previamente etiquetados.

La variable objetivo se define a partir de las etiquetas generadas en el apartado 5.4 mediante la simulación de fallos:

- fault_label = 0: funcionamiento normal
- fault_label = 1: funcionamiento degradado

Estas etiquetas representan el estado de salud del sistema en cada instante y constituyen la base para el entrenamiento del modelo.

5.5.3. Selección y significado físico de las variables de entrada

La selección de variables de entrada se basa en el análisis exploratorio realizado previamente y en criterios de significado físico. Se utilizan únicamente variables con relación directa con la eficiencia energética y el estado del sistema, evitando redundancias innecesarias:

- EER
- $Q_{sensible}$
- $Q_{latente}$
- ΔT (incremento de temperatura antes y después del evaporador)
- $\Delta \omega$ (incremento de humedad absoluta antes y después del evaporador)
- $airflow_{m3h}$
- $MAIN_{kW}$

Esta selección garantiza que el modelo se alimente de variables interpretables desde el punto de vista físico y energético.

```
features = [
    'EER_inst',
    'Q_sensible',
    'Q_latente',
    'delta_T',
    'delta_h',
    'airflow_m3h',
    'MAIN_kW'
]

X = df_fault[features]
y = df_fault['fault_label']
```

5.5.4 Preparación del conjunto de datos

Para evaluar el rendimiento del modelo de forma objetiva, el conjunto de datos se divide en dos subconjuntos:

1. Un conjunto de entrenamiento utilizado para ajustar el modelo.
2. Un conjunto de prueba, utilizado para evaluar su capacidad de generalización.

```
from sklearn.model_selection import train_test_split

X_train, X_test, y_train, y_test = train_test_split(
    X, y,
    test_size=0.25,
    random_state=42,
    stratify=y
)
```

5.5.5 Selección del algoritmo Random Forest

Random forest es un algoritmo que funciona creando multiples arboles de decision durante el entrenamiento y combinando sus resultados (por votación mayoritaria o promedio) para obtener una predicción mas precisa y estable que un solo arbol, reduciendo el sobreajuste.

Se selecciona el algoritmo Random Forest como modelo predictivo principal [17], debido a su buen rendimiento en problemas industriales y su robusted frente al ruido en conjuntos de datos. Entre sus principales ventajas están:

- Capacidad para modelar relaciones no lineales
- Bajo riesgo de sobreajuste
- Buen comportamiento con variables de distinta naturaleza
- Posibilidad de analisis de importancia de variables

5.5.6 Entrenamiento del modelo

El modelo se entrena utilizando un conjunto de arboles de decisión, cada uno de los cuales aprende patrones distintos a partir de subconjuntos aleatorios formados entre los datos.

```
from sklearn.ensemble import RandomForestClassifier

rf_model = RandomForestClassifier(
    n_estimators=200,
    random_state=42,
    class_weight='balanced'
)

rf_model.fit(X_train, y_train)
```

El uso de pesos balanceados permite compensar posibles desequilibrios entre clases, habituales en problemas de detección de fallos.

5.5.7 Evaluación del rendimiento del modelo

Una vez entrenado, el modelo se evalúa sobre el conjunto de prueba para analizar su capacidad de identificar correctamente estados degradados.

```

from sklearn.metrics import accuracy_score, classification_report

y_pred = rf_model.predict(X_test)

accuracy = accuracy_score(y_test, y_pred)
accuracy

print(classification_report(y_test, y_pred))

```

El código nos devuelve la evaluación del modelo, cuyos atributos se explican a continuación:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	417
1	1.00	1.00	1.00	417
accuracy			1.00	834
macro avg	1.00	1.00	1.00	834
weighted avg	1.00	1.00	1.00	834

Figura 5.24: Atributos de evaluación del modelo

Precisión

De todos los casos que el modelo predice como “mantenimiento requerido”, indica cuántos son realmente correctos

$$\text{Precisión} = \frac{\text{Verdaderos Positivos (VP)}}{\text{Verdaderos Positivos (VP)} + \text{Falsos Positivos (FP)}}$$

Indica la fiabilidad de las alertas positivas, y es muy útil cuando los falsos positivos tienen un coste elevado (por ejemplo, paradas no deseadas innecesarias)

Sensibilidad

La sensibilidad (recall) indica cuantos casos en los que si se requiere mantenimiento en realidad, logra detectar el modelo

$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos (VP)}}{\text{Verdaderos Positivos (VP)} + \text{Falsos Negativos (FN)}}$$

Mide la capacidad del modelo de detectar todos los fallos reales. La importancia de la sensibilidad es evidente, ya que no detectar un fallo podría ser crítico.

F1-score

Es la media armónica entre precisión y sensibilidad, resumiendo ambas métricas en una sola

$$F1 = \frac{\text{Precisión} * \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

Toma valores entre 0 y 1, siendo mejor cuanto más cerca de 1 está. Es útil cuando se necesita un equilibrio entre no dar falsas alarmas y no dejar pasar fallos reales.

Matriz de confusión

La matriz de confusión permite analizar el equilibrio entre falsas alarmas y fallos no detectados, clave en aplicación a casos reales. Se obtiene mediante el siguiente código.

```
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt

cm = confusion_matrix(y_test, y_pred)

fig, ax = plt.subplots(figsize=(4, 4))
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', ax=ax)
ax.set_xlabel('Predicción')
ax.set_ylabel('Valor real')
ax.set_title('Matriz de confusión')
plt.tight_layout()
plt.show()
```




Figura 5.25: Matriz de confusión del sistema

5.5.8 Interpretabilidad del modelo

Una de las ventajas del modelo Random Forest es que ofrece la posibilidad de analizar las variables de entrada, lo que permite interpretar el proceso de decisión del modelo.

```
importance_df = pd.DataFrame({
    'Variable': features,
    'Importancia': rf_model.feature_importances_
}).sort_values('Importancia', ascending=False)

fig, ax = plt.subplots(figsize=(6, 4))
ax.barh(importance_df['Variable'], importance_df['Importancia'])
ax.set_title('Importancia de las variables en el modelo')
ax.invert_yaxis()
plt.tight_layout()
plt.show()
```




Figura 5.26: Importancia de las variables en el modelo de mantenimiento predictivo

5.5.9 Discusión y limitaciones

Los resultados obtenidos muestran que es posible identificar estados de degradación progresiva de la unidad Rooftop a partir de variables energéticas y operativas con significado físico, validando el enfoque propuesto de mantenimiento predictivo basado en datos.

No obstante, hay que recordar que el modelo simulado y las etiquetas de fallo han sido generados sobre un único sistema específico. En aplicaciones reales sería necesario validar el modelo con datos históricos de fallo reales, incorporar mayor diversidad de escenarios operativos y considerar variables adicionales como condiciones ambientales.

Aun así, el enfoque desarrollado evidencia el potencial de la combinación entre fundamentos termodinámicos y técnicas de aprendizaje automático como base para estrategias de mantenimiento predictivo robustas y escalables.

6 CASO PRÁCTICO 2 - CONGELADORES

Este capítulo aplica la misma metodología de mantenimiento predictivo a un conjunto de congeladores industriales utilizados para el almacenamiento de botes de sellante. A diferencia del caso anterior, este escenario se centra exclusivamente en la monitorización de temperaturas internas, lo que reduce el número de variables disponibles para el análisis pero a la vez requiere una interpretación cuidadosa de los patrones térmicos.

Este segundo caso práctico se plantea siguiendo el mismo enfoque de análisis desarrollado en el capítulo anterior, basado en la ingeniería de datos aplicada a variables operativas y energéticas con el objetivo de caracterizar el comportamiento del sistema y detectar posibles desviaciones en su comportamiento.

6.1. Dataset utilizado

El conjunto de datos es sencillo y corresponde a lecturas de temperatura de varios congeladores (CONG 1, CONG 2, etc.), registradas con una resolución temporal de un minuto entre los meses de Abril y Mayo del 2025. Cada columna representa un congelador y la primera columna corresponde al tiempo en el que se registran los datos.

Fecha/hora	Instante en el que se toman los datos
CONG 1 - CONG 10	Temperaturas de los congeladores en cada instante

Tabla 6.1: Formato de los datos recogidos en los congeladores

El archivo es cargado con la siguiente instrucción:

```

import pandas as pd

# Cargar y preprocesar el dataset
file_path = "Informe Mensual Congeladores R2.xlsx"
df = pd.read_excel(file_path)

# Renombrar la primera columna como TIME y convertir a datetime
df.rename(columns={df.columns[0]: "TIME"}, inplace=True)
df["TIME"] = pd.to_datetime(df["TIME"])
df = df.set_index("TIME").sort_index()

# Eliminar columnas completamente vacías y convertir datos a numéricos
df = df.dropna(axis=1, how="all")
df = df.apply(pd.to_numeric, errors="coerce")

```

Como dato a tener en cuenta, se ha tomado un conjunto de datos que incluye el apagón nacional del 28 de abril, por lo que en muchos gráficos vamos a observar aumentos bruscos de temperaturas en esa zona y huecos sin datos pertenecientes al período en el que los sensores estuvieron desconectados.

6.2. Variables clave e indicadores

Dado que la variable crítica para un congelador es la temperatura, se definen los siguientes KPI's

- Temperatura umbral (-42°C): temperatura que, de ser superada en el congelador, se pondría en riesgo el producto sellante.
- Tendencia a la deriva térmica: se conoce como deriva térmica el aumento progresivo de temperatura durante varios ciclos, sin que se produzca una recuperación.
- Picos bruscos: incrementos de temperatura superiores a 2°C en menos de una hora
- Interrupciones: periodos sin datos que pueden asociarse a apagones o fallos de comunicación con los sensores

6.3. Activaciones de mantenimiento

En esta sección se visualiza la evolución temporal de las temperaturas registradas en los congeladores, con el objetivo de identificar comportamientos anómalos que puedan justificar acciones de mantenimiento predictivo. Dado que estos dispositivos deben operar por debajo de un umbral crítico de temperatura para conservar el sellante en condiciones óptimas, se ha establecido una referencia de control en -42°C, según especificaciones técnicas del proceso.

Para facilitar el análisis, se han empleado dos enfoques de visualización complementarios:

6.3.1. Representación conjunta

Se representan en un solo gráfico las temperaturas de todos los congeladores. Esto permite observar tendencias generales, comparar dispositivos entre si y detectar si alguno ha superado el umbral de temperatura. Se ha incluido una línea de referencia en -42°C. Primero se representa una franja más estrecha, sin tener en cuenta el apagón, para que se observen mejor las fluctuaciones, y después se incluye el rango completo con las temperaturas durante el apagón. El apagón se ha representado sombreándolo en naranja

```
import matplotlib.pyplot as plt
import pandas as pd

# Supongamos que df_filtrado ya contiene los datos limpios y que el índice es datetime
# apagón entre el 28 de abril de 2025 a las 12:00 y las 23:00
apagado_inicio = pd.to_datetime("2025-04-28 12:00")
apagado_fin = pd.to_datetime("2025-04-28 23:00")

# Crear gráfico
plt.figure(figsize=(16, 6))
for col in df_filtrado.columns:
    plt.plot(df_filtrado.index, df_filtrado[col], label=col, linewidth=1.2, alpha=0.8)

# Línea del umbral crítico
plt.axhline(-42, color="red", linestyle="--", label="Umbral -42 °C")

# Sombreado del periodo del apagón
plt.axvspan(apagado_inicio, apagado_fin, color='orange', alpha=0.3, label="Apagón 28/04/2025")

# Ajustes de eje y
plt.ylim(-47.5, -37.5)

# Estética del gráfico
plt.title("Temperatura de los congeladores con evento de apagón (abril-mayo 2025)")
plt.xlabel("Fecha")
plt.ylabel("Temperatura (°C)")
plt.legend(loc="upper right", fontsize="small", ncol=2)
plt.grid(True, linestyle='--', alpha=0.3)
plt.tight_layout()
plt.show()
```




Figura 6.1: Temperatura de todos los congeladores en franja reducida de temperaturas

Y ahora con el rango completo de temperaturas:

```
# Cargar datos
df = pd.read_excel("Informe Mensual Congeladores R2.xlsx")

# Preparación del dataset
df.rename(columns={df.columns[0]: "TIME"}, inplace=True)
df["TIME"] = pd.to_datetime(df["TIME"])
df.set_index("TIME", inplace=True)
df = df.sort_index()

# Eliminar columnas vacías y convertir valores
df = df.dropna(axis=1, how="all")
df = df.apply(pd.to_numeric, errors="coerce")

# Filtrar columnas con al menos el 95% de datos válidos
min_valid = int(0.95 * len(df))
cols_validas = df.columns[df.notna().sum() > min_valid]
df_filtrado = df[cols_validas]

# Representar todos los congeladores válidos en un mismo gráfico
plt.figure(figsize=(16, 6))
for col in df_filtrado.columns:
    plt.plot(df_filtrado.index, df_filtrado[col], label=col, linewidth=1.2, alpha=0.8)

plt.axhline(-42, color="red", linestyle="--", label="Umbral -42 °C")
plt.title("Temperatura de todos los congeladores válidos (abril-mayo 2025)")
plt.xlabel("Fecha")
plt.ylabel("Temperatura (°C)")
plt.legend(loc="upper right", fontsize="small", ncol=2)
plt.grid(True, linestyle='--', alpha=0.3)
plt.tight_layout()
plt.show()
```




Figura 6.2: Temperatura de todos los congeladores en franja completa de temperaturas

6.3.2. Representación individual por congelador

Complementariamente, se han generado gráficos individuales para cada congelador. Los objetivos de esta representación son:

- Observar tendencias específicas (fluctuaciones, picos o mantenimientos correctivos)
- Detectar patrones de comportamiento anómalo dilatados en el tiempo
- Analizar la respuesta de cada equipo frente a acciones concretas, como apertura de puertas, desconexiones, o el apagón general del 28 de abril.

La representación individual es clave para identificar fallos en dispositivos concretos que podrían pasar desapercibidos en la representación conjunta.

```
# Gráficos individuales para cada congelador
for col in df_filtrado.columns:
    plt.figure(figsize=(12, 4))
    plt.plot(df_filtrado.index, df_filtrado[col], label=col, color="tab:blue", linewidth=1.8)
    plt.axhline(-42, color="red", linestyle="--", label="Umbral -42 °C")
    plt.title(f"Temperatura - {col}")
    plt.xlabel("Fecha")
    plt.ylabel("Temperatura (°C)")
    plt.legend()
    plt.grid(True, linestyle='--', alpha=0.3)
    plt.tight_layout()
    plt.show()
```

Con este código se crean los gráficos individuales:




Figura 6.3: Temperatura del congelador 1




Figura 6.4: Temperatura del congelador 2.




Figura 6.5: Temperatura del congelador 3




Figura 6.6: Temperatura del congelador 4.




Figura 6.7: Temperatura del congelador 5




Figura 6.8: Temperatura del congelador 6




Figura 6.9: Temperatura del congelador 7




Figura 6.10: Temperatura del congelador 8




Figura 6.11: Temperatura del congelador 9.




Figura 6.12: Temperatura del congelador 10

En conjunto, esta sección demuestra cómo herramientas básicas de visualización en Python pueden ser aplicadas con efectividad para mejorar la vigilancia operativa de sistemas críticos, anticipando condiciones que puedan comprometer el proceso productivo o la seguridad del producto almacenado.

6.4. Reglas de activación de mantenimiento

Dado que se observan varios episodios reales de comportamiento anómalo, no se ha considerado necesario crear simulación de fallos como se hizo con los sistemas de climatización.

Se define una lógica de activación de mantenimiento basada en reglas aplicadas sobre los datos reales. Para cada congelador se crea una bandera binaria como ya se hizo en climatización, “*mantenimiento_CONG_X*”, que se programa para activarse si:

- Se superan los -42°C
- Se detecta un aumento acumulado de más de 2°C durante un periodo sostenido de al menos 120 minutos consecutivos (deriva térmica).

Estas condiciones permiten identificar tanto fallos progresivos como eventos abruptos. A través de esta estrategia se pueden generar alertas específicas por congelador, permitiendo obtener un diagnóstico más preciso y una planificación de mantenimiento adaptada a cada equipo.

```
def detectar_fallo_completo(serie):  
    # Condición 1: temperatura mayor a -42 °C  
    sobre_umbral = serie > -42  
  
    # Condición 2: aumento acumulado > 2 °C en 3 registros consecutivos  
    deriva_termica = serie.diff().rolling(3).sum() > 2.0  
  
    # Cualquier condición activa el mantenimiento  
    condiciones = sobre_umbral | deriva_termica  
    return condiciones.astype(int)
```

6.5. Visualización de activaciones de mantenimiento

Una vez generadas las banderas de mantenimiento individual para cada congelador, se procede a representar gráficamente las activaciones detectadas. Estas visualizaciones permiten validar que las alertas se corresponden con episodios reales de riesgo térmico y facilitan una inspección visual rápida del estado de cada equipo.

Para ello, se ha utilizado un ejemplo representativo (Congelador 2) y se ha graficado su evolución térmica junto con los puntos en los que se activa la alerta de mantenimiento. La línea roja horizontal representa el umbral de -42°C . Los puntos marcados corresponden a instantes en los que la temperatura supera el límite establecido o forman parte de una tendencia de deriva térmica identificada por las reglas de mantenimiento.

```
cong = "CONG 2" # nombre del congelador

plt.figure(figsize=(14, 5))
plt.plot(df.index, df[cong], label=cong, alpha=0.7)
plt.scatter(df.index[df[f"mantenimiento_{cong}"] == 1],
            df[cong][df[f"mantenimiento_{cong}"] == 1],
            color='red', label="Mantenimiento Requerido", s=20)
plt.axhline(-42, color='red', linestyle='--', label="Umbral -42 °C")
plt.title(f"Temperatura y alertas de mantenimiento en {cong}")
plt.ylabel("Temperatura (°C)")
plt.legend()
plt.tight_layout()
plt.show()
```




Figura 6.13: Puntos de mantenimiento requerido del congelador 2

Podríamos representar los puntos de mantenimiento requerido de cualquier congelador cambiando el nombre del congelador en la primera línea de código por “CONG X” según el que quisiéramos visualizar.

Este ejercicio permite validar visualmente que las alertas generadas por el sistema tienen sentido físico y se corresponden con momentos reales de riesgo o comportamiento inusual.

6.6. Conclusión

Este caso demuestra que, incluso con variables limitadas como la temperatura, es posible aplicar técnicas de mantenimiento predictivo efectivas. La observación de tendencias reales, unida a la definición de reglas lógicas y visualizaciones claras, permite anticipar riesgos antes de que la integridad del producto almacenado se vea comprometida.

Además, el sistema ha demostrado ser capaz de diferenciar entre comportamientos atribuibles a fallos comunes internos (deriva térmica) y eventos extraordinarios y externos como el apagón nacional. Esto refuerza la utilidad de las herramientas Python como soporte para la toma de decisiones en entornos industriales.

El análisis de este segundo sistema de refrigeración refuerza la utilidad del enfoque basado en datos desarrollado en el capítulo anterior, mostrando que el estudio de variables energéticas y operativas permite caracterizar el comportamiento del sistema y constituye una base adecuada para el desarrollo de estrategias de mantenimiento predictivo.

Durante el periodo analizado se identificaron varios episodios de superación del umbral de -42°C , así como eventos excepcionales asociados al apagón nacional del 28 de abril, demostrando la capacidad del método para distinguir entre desviaciones operativas y perturbaciones externas.

7 CONCLUSIONES

7.1. Conclusiones generales

El presente Trabajo de Fin de Grado ha permitido desarrollar una metodología de mantenimiento predictivo basada en ingeniería de datos y programación en Python, aplicada a sistemas de climatización y refrigeración industrial. A lo largo del trabajo se han combinado conceptos de mantenimiento predictivo, análisis de datos y eficiencia energética con el objetivo de transformar datos operativos en información útil para la toma de decisiones.

En el caso práctico desarrollado sobre una unidad rooftop, se ha realizado un proceso completo de adquisición, limpieza, transformación y análisis de datos procedentes de un sistema de climatización real. A partir de las variables registradas por los sensores ha sido posible caracterizar el comportamiento energético de la instalación, estimar indicadores de rendimiento como el EER y el SEER, analizar la influencia de las condiciones ambientales sobre la eficiencia del sistema y estudiar la contribución de fenómenos como la carga sensible, la carga latente o la utilización de aire exterior mediante economizador.

Los resultados obtenidos muestran que el análisis de datos permite comprender el comportamiento operativo de la instalación con un nivel de detalle difícilmente alcanzable mediante inspecciones convencionales. Se ha comprobado que la combinación de variables térmicas, eléctricas y psicométricas proporciona una visión global del estado de funcionamiento del equipo y facilita la detección de comportamientos anómalos.

Como parte del trabajo se han desarrollado además escenarios de degradación simulados representativos de fallos habituales en sistemas de climatización, como la reducción del caudal de aire o la degradación del rendimiento del compresor. Estos escenarios han permitido evaluar el impacto de dichas anomalías sobre los indicadores energéticos y generar un conjunto de datos etiquetado para el entrenamiento de modelos predictivos.

A partir de estos datos se ha implementado un modelo de clasificación basado en Random Forest capaz de diferenciar entre condiciones normales de funcionamiento y estados degradados simulados. Aunque el modelo ha sido entrenado utilizando datos generados artificialmente, los resultados obtenidos demuestran el potencial de las técnicas de aprendizaje automático como herramienta de apoyo a la detección temprana de anomalías en sistemas de climatización.

Finalmente, se ha desarrollado un segundo caso práctico aplicado a congeladores industriales. En este caso se ha diseñado un sistema de supervisión basado en reglas y umbrales operativos capaz de identificar situaciones de riesgo relacionadas con desviaciones térmicas y pérdidas de capacidad de refrigeración.

Los resultados obtenidos muestran que incluso en conjuntos de datos con un número reducido de variables es posible implantar estrategias sencillas de mantenimiento predictivo que aporten valor operativo y permitan anticipar incidencias.

En conjunto, los resultados obtenidos demuestran que la combinación de conocimientos de ingeniería térmica, análisis de datos y herramientas de programación constituye una base sólida para el desarrollo de estrategias de mantenimiento predictivo aplicables a entornos industriales reales.

7.2. Contribuciones del trabajo

Las principales contribuciones de este trabajo pueden resumirse en los siguientes puntos:

- Desarrollo de una metodología completa de análisis de datos aplicada al mantenimiento predictivo utilizando Python y herramientas de código abierto.
- Aplicación de la metodología a un sistema de climatización real mediante el estudio de variables térmicas, eléctricas y psicométricas.
- Estimación y análisis de indicadores energéticos como el EER y el SEER a partir de datos operativos registrados por sensores.
- Evaluación del comportamiento energético de una unidad rooftop y análisis de la influencia de las condiciones ambientales sobre su rendimiento.
- Generación de escenarios de degradación simulados representativos de fallos habituales en sistemas de climatización.
- Desarrollo de un modelo de clasificación basado en Random Forest para la detección automática de estados degradados.
- Diseño de un sistema de monitorización basado en reglas para la supervisión de congeladores industriales.
- Demostración de la viabilidad de aplicar técnicas de mantenimiento predictivo utilizando exclusivamente datos históricos y herramientas de programación accesibles.

7.3. Trabajos futuros

Las posibilidades de evolución de este trabajo son numerosas y permitirían aumentar tanto la precisión de los modelos desarrollados como su aplicabilidad en entornos industriales reales.

Una primera línea de trabajo consistiría en disponer de conjuntos de datos históricos que incluyan averías reales documentadas. Esto permitiría entrenar y validar modelos predictivos utilizando eventos reales de fallo, sustituyendo parcialmente los escenarios simulados empleados en este estudio.

Resultaría de interés ampliar el número de variables monitorizadas mediante la incorporación de nuevos sensores relacionados con vibraciones, calidad del aire, consumo energético detallado o parámetros específicos del circuito frigorífico. Una mayor cantidad de información permitiría

desarrollar modelos más robustos y sensibles a diferentes modos de fallo.

Otra posible evolución consistiría en la aplicación de técnicas más avanzadas de aprendizaje automático, incluyendo modelos de detección de anomalías no supervisados, algoritmos de aprendizaje profundo o sistemas capaces de estimar la vida útil remanente de los componentes.

En el ámbito de la explotación industrial, una línea especialmente interesante sería la integración de estos modelos en plataformas de supervisión en tiempo real, permitiendo generar alertas automáticas y facilitar la toma de decisiones por parte de los responsables de mantenimiento.

Por último, la metodología desarrollada podría extenderse a otros activos industriales más allá de los sistemas de climatización, adaptándose a diferentes procesos productivos y contribuyendo a la implantación progresiva de estrategias de mantenimiento predictivo dentro del marco de la industria 4.0

REFERENCIAS

- [1] W. McKinney, *Python for Data Analysis*, 3rd ed. Sebastopol, CA, USA: O'Reilly Media, 2022.
- [2] S. L. Brunton y J. N. Kutz, *Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control*, 2nd ed. Cambridge, UK: Cambridge University Press, 2022.
- [3] A. Das, *Machine Learning for Predictive Maintenance*. Sebastopol, CA, USA: O'Reilly Media, 2023.
- [4] Universitat Oberta de Catalunya, *Mantenimiento predictivo y monitorización de condición*. Disponible en: <https://openaccess.uoc.edu>
- [5] Tractian, “Técnicas de mantenimiento predictivo utilizadas en la industria”. Disponible en: <https://traction.com/es/blog/tecnicas-de-mantenimiento-predictivo-utilizadas-en-la-industria>
- [6] Preditec, “Análisis de lubricantes”. Disponible en: <https://www.preditec.com>
- [7] Preditec, “Ultrasonidos aplicados al mantenimiento predictivo”. Disponible en: <https://www.preditec.com>
- [8] VisionTIR, “Termografía infrarroja: cámaras termográficas y termómetros infrarrojos”. Disponible en: <https://visiontir.com>
- [9] Solex, “Monitoreo de condiciones y mantenimiento predictivo: diferencias y ventajas”. Disponible en: <https://www.solex.biz>
- [10] Infrasppeak, “Mantenimiento predictivo”. Disponible en: <https://blog.infrasppeak.com>
- [11] Tameson, “Fundamentos HVAC”. Disponible en: <https://tameson.es/pages/fundamentos-hvac>
- [12] SafetyCulture, “Componentes de un sistema HVAC”. Disponible en: <https://safetyculture.com>
- [13] GoMetrics, “Sistemas HVAC”. Disponible en: <https://www.gometrics.net>
- [14] Cuerva Energía, “HVAC: qué es y cómo funciona”. Disponible en: <https://cuervaenergia.com>
- [15] Mendeley Data, “RTU Rooftop Unit Dataset”. Disponible en: <https://data.mendeley.com/datasets/9h6gpbhj5k/1>
- [16] D. Li et al., “Bringing Automated Fault Detection and Diagnostics to Rooftop Units”, *ASME Journal of Sustainable Buildings and Infrastructure Systems*.
- [17] J. Barrios, “La matriz de confusión y sus métricas”. Disponible en: <https://www.juanbarrios.com>

GLOSARIO

AHU: Air Handling Unit	20
BMS: Building Management System	18
CFM: Cubic Feet per Minute	37
COP: Coefficient of Performance	24
EDA: Exploratory Data Analysis	40
EER: Energy Efficiency Ratio	24
FCS: Factor de Calor Sensible	56
FDD: Fault Detection and Diagnosis	31
FFT: Fast Fourier Transform	7
HVAC: Heating, Ventilation and Air Conditioning	17
IAQ: Indoor Air Quality	18
KPI: Key Performance Indicator	73
RTU: Rooftop Unit	19
SCOP: Seasonal Coefficient of Performance	25
SEER: Seasonal Energy Efficiency Ratio	25

