

Diseño de un sistema de monitorización para fines de mantenimiento predictivo aplicado a un
compresor de aire de pistón

Michael Andrés Mandón Santiago

Trabajo de Grado para optar al título de Ingeniero Electrónico

Director

Rodolfo Villamizar Mejía

Doctor en tecnologías de la información

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Electrónica

Bucaramanga

2026

Tabla de Contenido

	Introducción	9
1	Objetivos	13
1.1	Objetivo general	13
1.2	Objetivos específicos	13
2	Marco conceptual	14
2.1	Generalidades	14
2.1.1	Compresor de aire de pistón	14
2.1.2	Mantenimiento industrial	15
2.1.2.1	Mantenimiento basado en condición (CBM)	16
2.1.2.2	Mantenimiento predictivo	16
2.1.3	Sistemas de monitorización en línea	17
2.1.4	Análisis de componentes principales (PCA)	18
2.1.5	Estadísticos T^2 y Q	18
2.1.6	Modelo multivariado	19
2.2	Estado del arte	20
3	Metodología	23
3.1	VARIABLES CRÍTICAS MONITORIZADAS	23
3.2	Diseño de la arquitectura conceptual del sistema de monitorización	24
3.3	Entrenamiento del modelo multivariado	29
4	Validación experimental	33
4.1	Data-set	33

SISTEMA DE MONITORIZACIÓN PARA COMPRESOR DE AIRE	3
4.2 Validación mediante datos disponibles en la literatura	35
5 Análisis de resultados	39
5.1 Proyección a espacio PCA	39
5.2 Detección de fallos mediante Q vs T^2	41
5.3 Evaluación de desempeño del clasificador	42
6 Conclusiones	46
7 Recomendaciones y trabajo futuro	48
Referencias	49
Apéndices	55

Lista de Figuras

1	Compresor de aire de pistón de accionamiento directo industrial.	15
2	Esquema común del sistema de monitorización.	17
3	Esquema de monitorización propuesto mediante bloques funcionales.	27
4	Diagrama de bloques funcionales de la etapa de entrenamiento del modelo.	29
5	Análisis de varianza explicada por componentes principales.	32
6	Diagrama de bloques funcionales de la etapa de validación del modelo.	35
7	PC1 vs PC2 (Conjunto de muestras completo).	40
8	PC1 vs PC2 (Conjunto de últimas 50 muestras).	40
9	Gráfica Q vs T ² de todos los estados (Conjunto de muestras completo).	41
10	Gráfica Q vs T ² de todos los estados (Conjunto de muestras completo) (Acerca- miento).	42
11	Gráfica Q vs T ² de todos los estados (Conjunto de últimas 50 muestras).	43
12	Gráfica Q vs T ² de todos los estados (Conjunto de últimas 50 muestras) (Acerca- miento).	43
13	Matriz de confusión (Conjunto de muestras completo).	44
14	Matriz de confusión (Conjunto de últimas 50 muestras).	44

Lista de Tablas

1	Parámetros medidos y componentes evaluados.	24
2	Reporte de clasificación (Conjunto de muestras completo).	45
3	Reporte de clasificación (Conjunto de últimas 50 muestras)	45
4	Dispositivos DAQ propuestos.	57
5	Sensores propuestos de precio bajo.	57
6	Sensores propuestos de precio medio.	58
7	Sensores propuestos de precio alto.	58

Lista de Apéndices

Apéndice A: Repositorio en GitHub (Código) 55

Apéndice B: Conjunto de datos (Dataset)56

Apéndice C: Dispositivos propuestos para la implementación del sistema57

Apéndice D: Descripción de variables monitorizadas 60

Resumen

Título: Diseño de un sistema de monitorización para fines de mantenimiento predictivo aplicado a un compresor de aire de pistón.¹

Autor: Michael Andrés Mandón Santiago.²

Palabras Clave: Industria 4.0, compresor de aire, sensores, mantenimiento predictivo, monitoreo en línea, PCA.

Descripción: Con el paso del tiempo, el avance tecnológico ha redefinido la manera en que opera la industria, y el sector de la generación de energía ha sido uno de los más influenciados por esta evolución. En este contexto, equipos como los compresores de aire han adquirido un papel fundamental gracias a su versatilidad y aplicación en diversos procesos industriales. Sin embargo, persisten desafíos importantes relacionados con la eficiencia operativa y los elevados costos derivados del mantenimiento, producto de fallas recurrentes que afectan la continuidad de las operaciones. En respuesta a esta necesidad, el presente proyecto propone el diseño de un sistema de monitoreo en línea enfocado en la implementación de estrategias de mantenimiento predictivo para compresores de aire de pistón. Como resultado, se obtuvo un modelo multivariado capaz de detectar y clasificar anticipadamente cuatro de los tipos de fallos más recurrentes en la industria. Con el fin de impactar positivamente en la reducción de los costos de mantenimiento, la disponibilidad operativa y la disminución del riesgo potencial del personal de trabajo.

¹Trabajo de Grado

²Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y telecomunicaciones. Director: Rodolfo Villamizar Mejía, Magíster en sistemas de distribución de energía eléctrica.

Abstract

Title: Design of a monitoring system for predictive maintenance purposes applied to a piston air compressor. ¹

Author: Michael Andrés Mandón Santiago. ²

Keywords: Industry 4.0, air compressor, sensors, predictive maintenance, online monitoring, PCA.

Description: Over time, technological advances have redefined the way the industry operates, and the power generation sector has been one of the most influenced by this evolution. In this context, equipment such as air compressors has taken on a fundamental role thanks to its versatility and application in various industrial processes. However, significant challenges remain in terms of operational efficiency and high maintenance costs resulting from recurring failures that affect the continuity of operations. In response to this need, this project proposes the design of an online monitoring system focused on the implementation of predictive maintenance strategies for piston air compressors. As a result, a multivariate model was obtained that is capable of detecting and classifying in advance four of the most recurrent types of failures in the industry. The aim is to have a positive impact on reducing maintenance costs, improving operational availability, and decreasing the potential risk to workers.

¹Degree Project

²Faculty of Physical-Mechanical Engineering, School of Electrical, Electronic, and Telecommunications Engineering. Director: Rodolfo Villamizar Mejía, Master in Electric power distribution systems.

Introducción

En la actualidad, los sistemas industriales demandan una operación continua, eficiente y segura, lo que ha impulsado la adopción de estrategias de mantenimiento más modernas y óptimas. Dentro de este panorama, los compresores de aire se destacan como componentes fundamentales en numerosas aplicaciones industriales, debido a su capacidad para suministrar aire comprimido de forma constante y confiable como fuente de energía para operar herramientas, maquinaria y sistemas con altos niveles de eficiencia energética. En Colombia, según un estudio realizado por la Unidad de planeación minero energética (UPME), se estima que aproximadamente el 29 % del consumo total de electricidad en la industria, corresponde a sistemas de aire comprimido, siendo los compresores de pistón los más utilizados en aplicaciones de baja demanda que requieren funcionamiento continuo (Narváez, 2018). Sin embargo, el funcionamiento prolongado y las condiciones exigentes de operación a las que están sometidos estos compresores los convierten en elementos susceptibles a fallos que, si no son detectados a tiempo, pueden generar tiempos de inactividad, pérdidas económicas y riesgos para la seguridad operativa. Fractal, una empresa líder en soluciones de mantenimiento preventivo y predictivo para plantas manufactureras en Latinoamérica y Europa (España y Portugal) en un comunicado reciente, destacó la importancia de evitar fallas operativas, ya que la falta de mantenimiento adecuado puede generar una pérdida promedio anual de hasta 125 mil dólares, afectando gravemente los presupuestos y utilidades de las empresas de nivel intermedio (Fractal, s.f.). Estas investigaciones evidencian la ausencia de estrategias de mantenimiento orientadas a anticipar fallas potenciales, mediante el monitoreo continuo de los parámetros críticos del equipo. (Zhai y cols., 2020).

En Colombia, hasta ahora no se encuentran registros claros sobre la aplicación de este tipo

de mantenimiento, lo que supone una dificultad para el sector. Sin embargo, también abre una oportunidad para empezar a adoptarlo, probar sus beneficios y mejorar la forma en que se cuidan y operan los equipos en la industria.

A pesar de la importancia operativa que tienen los compresores de aire en el entorno industrial, muchas empresas aún dependen de esquemas de mantenimiento correctivo o preventivo basados en rutinas fijas y no en el estado real del equipo. Este enfoque tradicional, aunque útil en ciertos contextos, no garantiza una intervención oportuna frente a fallas incipientes, ya que no considera las condiciones dinámicas de operación ni las variaciones en el desgaste de los componentes mecánicos. La falta de información en tiempo real sobre el estado de variables críticas, como la presión, la temperatura, las vibraciones o el consumo eléctrico, limita la capacidad de diagnóstico anticipado, lo cual puede derivar en fallos inesperados, interrupciones en la producción y sobre costos por reparaciones de emergencia. De hecho, estudios indican que más del 60% de las fallas en equipos rotativos podrían haberse evitado mediante técnicas de monitorización basadas en condición (Deloitte, 2022).

El desarrollo de un sistema de monitorización en línea orientado al mantenimiento predictivo representa una oportunidad clave para optimizar la operación y gestión de activos industriales. Implementar este tipo de solución permite no solo detectar condiciones anómalas con antelación, sino también establecer patrones de comportamiento que faciliten la toma de decisiones basadas en datos reales, reduciendo la incertidumbre en la planificación del mantenimiento (Dwivedi y cols., 2025), prolongando la vida útil de los componentes, disminuyendo los costos de reparación y evitando paradas inesperadas del proceso productivo. Además, esta solución promueve una cultura de mantenimiento más proactiva, alineada con los principios de la Industria 4.0, que integra

tecnologías digitales para aumentar la eficiencia, la sostenibilidad y la competitividad industrial (González-Sánchez y cols., 2020).

Anteriormente, el mantenimiento predictivo estaba asociado a la medición de algunos de los parámetros de funcionamiento de los equipos acompañado de un sistema de adquisición de datos en tiempo real (DAQ) y de tecnologías de infrarrojos (Mobley, 2002), lo que suponía más un enfoque preventivo. De esta manera, se lograban detectar medidas anómalas y el personal trabajador se encargaba de tomar decisiones operativas. Este sistema lograba anticipar fallos en la maquinaria, pero a su vez, debido a su fuerte dependencia del personal operativo, carecía de confiabilidad y eficiencia. La solución propuesta consiste en el diseño de un sistema de monitorización en línea enfocado en la detección y clasificación anticipada de cuatro de los tipos de fallos más recurrentes en los compresores de aire de pistón mediante un modelo multivariado basado en el análisis de componentes principales (PCA). El análisis PCA fue elegido por su capacidad de modelar el comportamiento normal del sistema, capturar la correlación entre múltiples variables y reducir la dimensión de los datos. De este modo, se logró la ausencia de modelos físicos complejos reduciendo la dificultad y el costo de implementación lo que lo hace especialmente adecuado para mantenimiento predictivo en todo tipo de sistemas industriales. Esta flexibilidad permitirá que empresas de diferentes tamaños accedan a tecnologías de mantenimiento predictivo, tradicionalmente reservadas para sistemas de mayor inversión. En conjunto, estas mejoras no solo aumentan la eficiencia técnica y económica del sistema, sino que también contribuyen al desarrollo de entornos industriales más inteligentes, alineados con los principios de sostenibilidad y transformación digital. Como resultado principal del proyecto, se diseñó un esquema de monitorización basado en análisis multivariado mediante PCA, capaz de modelar el comportamiento normal del siste-

ma y detectar desviaciones asociadas a diferentes tipos de falla. El sistema permitió identificar y clasificar de manera efectiva fallas relacionadas con rodamientos ruidosos, bomba de agua ruidosa, radiador y válvulas sucios, utilizando los estadísticos T^2 y Q como indicadores de condición. La validación realizada evidenció una separación clara entre el estado saludable y cada tipo de falla, demostrando la viabilidad del enfoque como herramienta de apoyo para estrategias de mantenimiento predictivo en sistemas industriales. Se espera que la implementación del sistema de monitorización diseñado en esta propuesta contribuya significativamente a la mejora de la eficiencia operativa del compresor de aire de pistón, al proporcionar una herramienta capaz de identificar condiciones de funcionamiento anómalas antes de que estas se traduzcan en fallos críticos. Esto permitirá una reducción significativa de fallos importantes, costos de mantenimiento y una mejora en la disponibilidad operativa, según reportes de casos exitosos en entornos industriales similares (Kumar, 2025).

El presente documento está estructurado en cuatro capítulos: el primero presenta los conceptos previos y revisión de la literatura existente, el segundo describe la metodología empleada para dar solución al problema, el tercero presenta los resultados obtenidos y respectivas conclusiones y, finalmente, el cuarto establece los desafíos futuros para futuros proyectos que busquen complementar o competir la solución implementada. Se espera que los resultados de esta investigación contribuyan a la modernización de la industria en el ámbito nacional.

1. Objetivos

1.1. Objetivo general

Proponer un esquema de monitorización en línea de variables asociadas con la operación de un compresor de aire de pistón utilizado en la industria, con el fin de implementar a futuro un sistema de mantenimiento predictivo.

1.2. Objetivos específicos

Establecer los requerimientos de monitorización, considerando las especificaciones técnicas y operativas del compresor de aire de pistón y sus principales variables asociadas con el correcto funcionamiento.

Plantear un diseño de la solución a nivel de bloques funcionales definiendo los componentes necesarios para la implementación del sistema de monitorización, cumpliendo los requerimientos de monitorización establecidos previamente.

Validar el diseño de ingeniería propuesto mediante datos disponibles en la literatura.

2. Marco conceptual

En esta sección se definirán conceptos que son fundamentales para comprender de manera más precisa el contenido del proyecto de investigación, facilitando así la interpretación de la metodología utilizada, los resultados y las discusiones que se presentan a lo largo del estudio.

2.1. Generalidades

2.1.1. *Compresor de aire de pistón*

Un compresor de aire de pistón es una máquina diseñada para generar aire comprimido de forma continua y eficiente mediante energía mecánica, y su funcionamiento se basa en un ciclo de dos fases. Una vez encendido el compresor, empieza la fase de admisión en la cual el pistón desciende succionando aire a través de la válvula de admisión que está abierta mientras que, la válvula de descarga permanece cerrada. Luego en la fase de compresión, el pistón asciende con la válvula de admisión cerrada, comprimiendo el aire dentro del cilindro logrando que la presión y la temperatura interna aumenten. Finalmente, en la fase de descarga, al alcanzar la presión de trabajo, se abre la válvula de descarga y el aire comprimido sale hacia el tanque o línea de servicio. Este ciclo se repite continuamente y es controlado por un presostato que activa o desactiva la carga según la presión en el depósito. Mientras que este ciclo está en funcionamiento, la bomba de agua circula agua fría desde el exterior hacia la chaqueta del cilindro y/o intercambiadores permitiendo que el agua absorba calor generado por la compresión. De este mismo modo, la bomba de aceite acoplada al cigüeñal aspira aceite del cárter (a través de un filtro) y lo inyecta presurizado a los cojinetes principales, muñones de biela y pistón reduciendo fricción y retirando el calor de las piezas móviles (Kutz, 2014).

Existen diferentes tipos y configuraciones de compresores de aire de pistón, pero principalmente se basan en dos factores importantes. El primer factor es la acción de comprimir aire en un sentido o en ambos sentidos del movimiento del pistón. Y el otro factor importante por el cual se diferencia este tipo de compresor es el uso de aceite como sustancia de lubricación. Los compresores de aire de pistón exentos de aceite son utilizados idealmente para aplicaciones donde la pureza del aire es crucial, específicamente en la industria farmacéutica o alimenticia.

Figura 1

Compresor de aire de pistón de accionamiento directo industrial.



Nota. Adaptado de Atlas Copco.

2.1.2. Mantenimiento industrial

El mantenimiento industrial comprende el conjunto de actividades técnicas y administrativas destinadas a conservar, restaurar o mejorar la funcionalidad de los equipos y sistemas dentro de una planta de producción. Su correcta implementación influye directamente en la productividad, en la seguridad y en la eficiencia energética de los procesos industriales (Moblely, 2002).

Con el tiempo, las estrategias de mantenimiento han evolucionado. Tradicionalmente, se aplicaban modelos reactivos o correctivos, en los que las acciones se realizaban una vez ocurrida

la falla. Posteriormente, se adoptó el mantenimiento preventivo, basado en calendarios fijos o ciclos de uso. Sin embargo, ambos enfoques presentan limitaciones importantes, como altos costos por paradas innecesarias o por intervenciones tardías.

2.1.2.1. Mantenimiento basado en condición (CBM). El mantenimiento basado en condición (CBM) se fundamenta en la monitorización en tiempo real de variables críticas (como vibraciones, temperatura o presión), permitiendo detectar desviaciones que anticipan una posible falla. Este enfoque es la base para el desarrollo del mantenimiento predictivo, el cual emplea datos históricos y en tiempo real junto con técnicas de análisis avanzado para estimar el tiempo restante antes de una falla operativa (Lee y cols., 2014).

2.1.2.2. Mantenimiento predictivo. El mantenimiento predictivo se puede definir como el conjunto de técnicas y metodologías que permiten estimar el estado de salud de una máquina y determinar el momento óptimo para realizar intervenciones, basándose en el análisis de datos históricos y en tiempo real del equipo (Mobley, 2002). Las estrategias de mantenimiento predictivo suelen apoyarse en métodos basados en datos, que incluyen desde análisis estadísticos hasta algoritmos de aprendizaje automático. Desde hace varios años, se viene estudiando como diversas técnicas de diagnóstico y pronóstico, como el análisis de vibraciones y la estimación de vida remanente pueden integrarse en esquemas CBM (condition-based maintenance) para anticipar fallas con alta precisión (Jardine y cols., 2006). Más recientemente, el enfoque de los investigadores se basa en recopilar y comparar métodos data-driven (por ejemplo, redes neuronales, máquinas de vector soporte, entre otros) para sistemas industriales, demostrando mejoras en la exactitud de la predicción y la capacidad de adaptación a diferentes tipos de maquinaria (Zhang y cols., 2019).


2.1.3. *Sistemas de monitorización en línea*

Los sistemas de monitorización en línea consisten en arquitecturas integradas de sensores, adquisición de datos, procesamiento y visualización, que operan de forma continua para capturar y analizar parámetros críticos del equipo que se desea monitorizar (Lee y cols., 2014). En el bloque de sensado se seleccionan transductores industriales (por ejemplo, sensores piezoeléctricos de vibración, transductores de presión y termopares) adecuados a los rangos de operación del compresor. Posteriormente, los datos se acondicionan y digitalizan mediante módulos de adquisición (DAQ), que envían la información a un sistema de control o servidor mediante protocolos de comunicación (Modbus, Ethernet/IP, MQTT, entre otros).

El procesamiento de los datos puede implementarse localmente o en la nube, donde se aplican algoritmos de análisis avanzado y machine learning (Zhang y cols., 2019). Finalmente, una interfaz de usuario muestra gráficos de tendencias, alertas y reportes históricos, facilitando la toma de decisiones por parte del personal encargado del mantenimiento. Este enfoque modular garantiza escalabilidad y adaptabilidad a distintos entornos industriales, desde plantas pequeñas hasta entornos de gran producción.

Figura 2

Esquema común del sistema de monitorización.



2.1.4. *Análisis de componentes principales (PCA)*

El Análisis de Componentes Principales (PCA, por sus siglas en inglés Principal Component Analysis) es una técnica estadística empleada para reducir la dimensión de los datos manteniendo la mayor cantidad posible de información original. A través de transformaciones lineales, convierte las variables correlacionadas en un nuevo conjunto de variables no correlacionadas llamadas componentes principales, que son combinaciones de las variables originales. Estos componentes están ordenados según la cantidad de información que explican (Varianza). Los primeros concentran la mayor parte de la variabilidad del sistema, mientras que los últimos suelen corresponder a ruido. Por esta razón, se seleccionan solo los primeros componentes, logrando una reducción de dimensionalidad que simplifica el análisis sin perder el comportamiento esencial del sistema (Jolliffe y Cadima, 2016).

El procedimiento del PCA implica la normalización de las variables, el cálculo de la matriz de covarianza, la obtención de valores y vectores propios, y la proyección de los datos en el subespacio definido por los componentes más representativos. Esta técnica es ampliamente utilizada en ingeniería y análisis de datos para identificar patrones, eliminar redundancias y visualizar relaciones complejas entre variables. En el contexto industrial, el PCA permite comprender el comportamiento general de sistemas con una cantidad considerable de variables, siendo una herramienta clave para el análisis de datos y toma de decisiones adecuadas.

2.1.5. *Estadísticos T^2 y Q*

En los sistemas de monitorización basados en análisis multivariado, los estadísticos de Hotelling T^2 y Q son utilizados como indicadores fundamentales del estado de condición del sistema.

El estadístico T^2 permite cuantificar qué tan alejada se encuentra una medición dentro del modelo respecto al comportamiento normal del sistema considerando las relaciones entre todas las variables, es decir, mide desviaciones de patrones normales de comportamiento. Por su parte, el estadístico Q evalúa la parte de la señal que no puede ser explicada por el modelo normal, representando la energía asociada a comportamientos anómalos representados por patrones nuevos y diferentes asociados a elementos externos del sistema (Ketelaere y cols., 2015). En conjunto, T^2 y Q proporcionan una visión complementaria del estado del sistema, facilitando la detección temprana de fallas y la identificación de comportamientos anormales en aplicaciones de mantenimiento predictivo. El estadístico de Hotelling T^2 se define según la ecuación 2.1, mientras que el estadístico Q (SPE) se expresa en la ecuación 2.2.

$$T^2 = \sum_{i=1}^A \frac{t_i^2}{\lambda_i} \quad (2.1)$$

$$Q = \|X - \hat{X}\|^2 = \sum_{j=1}^m (x_j - \hat{x}_j)^2 \quad (2.2)$$

2.1.6. *Modelo multivariado*

En el contexto de este trabajo, un modelo multivariado es la representación matemática y estadística del comportamiento del compresor, construida a partir de las múltiples variables medidas por los sensores, con el fin de caracterizar su estado normal y sus condiciones de fallo mediante PCA (Montgomery y cols., 2019).

2.2. Estado del arte

Durante las últimas tres décadas, la investigación en detección de fallos, diagnóstico y mantenimiento predictivo (PdM) de compresores de aire ha evolucionado de manera progresiva, impulsada por la necesidad de mejorar la confiabilidad y la eficiencia de los sistemas industriales. Esta evolución se ha reflejado principalmente en las técnicas de adquisición de datos, los métodos de procesamiento de señales y los enfoques de diagnóstico empleados.

En una etapa inicial, desde mediados de la década de 1990 hasta finales de los años 2000, los estudios se centraron en compresores alternativos y en fallos de válvulas, utilizando redes neuronales superficiales y máquinas de soporte vectorial aplicadas a variables de proceso, señales eléctricas e indicadores termodinámicos, como los diagramas presión–volumen (James Li y Yu, 1995) (F. Wang y cols., 2010). Estos trabajos establecieron la monitorización multisensorial y el uso de características diseñadas manualmente como bases del diagnóstico de fallos.

Posteriormente, entre 2010 y 2015, se registraron avances significativos en el análisis de señales de vibración y emisión acústica. En este período se introdujeron técnicas de optimización, representaciones tiempo–frecuencia más informativas y los primeros enfoques de aprendizaje, lo que permitió mejorar la capacidad de detección y clasificación de fallos (Ahmed y cols., 2011) (Qin y cols., 2012) (Tran y cols., 2014) (Y. Wang y cols., 2015) (Keerqinhu y cols., 2016).

Entre 2016 y 2019, la bibliografía sobre compresores de aire de una sola etapa se amplió considerablemente. Una serie de trabajos (en particular los de Sugumaran y sus coautores) estandarizaron los procesos de vibración + ML para fallos de compresores de aire (aleteo de válvulas,

fugas, fallos de válvulas de retención, etc.) utilizando características estadísticas, wavelet, bosques aleatorios y clasificadores (Aravinth y cols., 2016)(Prashanth y Elangovan, 2019)(Sivakumar y Vaithyanathan, 2021)(S y V, 2023). Es importante destacar que se demostró la clasificación de fallos múltiples y combinados en compresores alternativos (válvulas + cojinetes, fallos de válvulas simples y combinados) utilizando DBN híbridas y características basadas en la dinámica(Tran y cols., 2018)(Cerrada y cols., 2020). La primera fusión multiparamétrica para compresores de aire (presión, temperatura, vibración, corriente, nivel de líquido) apareció en (H. Wang y cols., 2019).

En años recientes, aproximadamente entre 2021 y 2025, la investigación ha avanzado hacia arquitecturas de aprendizaje profundo más complejas, como redes convolucionales y modelos de aprendizaje por transferencia, con un mayor énfasis en la interpretabilidad física y la integración con plataformas IoT. El aprendizaje por transferencia con CNN y transformadores de visión preentrenados en imágenes de espectrogramas acústicos o derivados de vibraciones ha dado lugar a una precisión muy alta en la detección de fallos en compresores de aire(Srivatsan y cols., 2024)(Guo y cols., 2023). Los métodos basados en diagramas indicadores se han perfeccionado para utilizar características escalares físicamente significativas (área del bucle, centroide, presiones medias) y bases de datos de umbrales para diagnosticar válvulas, anillos de pistón y empaquetaduras(Lv y cols., 2022)(Wu y cols., 2023).

Por último, varios trabajos han implementado sistemas PdM industriales utilizando datos similares a los de SCADA y modelos de ML relativamente sencillos (por ejemplo, regresión más umbrales), integrados con bases de datos en la nube y dispositivos periféricos(Aminzadeh y cols., 2025)(Ciobotaru y cols., 2025)(Nambiar y cols., 2024)(Keerqinhu y cols., 2016). En conjunto, el campo ha pasado de una clasificación superficial, basada únicamente en válvulas y con caracterís-

ticas artesanales, a soluciones de PdM. En este contexto, este proyecto se presenta con un enfoque aplicado y alineado con las necesidades industriales en Colombia. El trabajo prioriza la definición de requerimientos y la estructuración funcional del sistema, sentando las bases para la futura implementación de estrategias de mantenimiento predictivo, y contribuyendo a reducir la brecha entre los desarrollos académicos y su aplicación en escenarios industriales reales.

3. Metodología

A lo largo de este capítulo se analizan y describen los procedimientos realizados para llevar a cabo este trabajo de grado. Se comienza con la explicación de lo que se proyectó realizar, el análisis de las opciones que se tenían a disposición, los métodos elegidos y una justificación posterior. Finalmente, se prepara al lector para la entrega del análisis de los resultados, que se exponen en el siguiente capítulo.

3.1. Variables críticas monitorizadas

Para llevar a cabo un esquema de monitorización adecuado, es necesario conocer el equipo o tipo de máquina que será monitorizado y como es su funcionamiento interno. Es por lo que a continuación, se describe detalladamente el proceso de funcionamiento del compresor de aire usado, se describen las variables monitorizadas propuestas en el conjunto de datos encontrado y la principal razón por la cual proporcionan un aporte significativo a los objetivos del proyecto. En la tabla 1, se encuentra la etiqueta de cada variable y el parámetro que mide. Adicionalmente, se realiza una breve descripción sobre el aporte de cada una de las variables para entender por qué fue monitorizada y los fallos que puede ayudar a predecir.

Conociendo el proceso y sus componentes principales, el autor Ahmet Okudan del conjunto de datos presentado en el apéndice B, realizó la elección de las variables más importantes a monitorizar, descritas a continuación en la Tabla 1. Además, se encuentra una descripción de la variable y cómo influye cada una de ellas en el comportamiento del compresor en el apéndice D.

Tabla 1*Parámetros medidos y componentes evaluados.*

Etiqueta (Unidad)	Definición
Id	Número de muestra
Rpm (rpm)	Revoluciones por minuto
Motor power (W)	Potencia del motor
Torque (N·m)	Torque del motor
Outlet pressure (bar)	Presión del aire en la salida
Air flow (L/min)	Flujo volumétrico de aire comprimido
Noise (dB)	Nivel de ruido medido cerca del compresor
Outlet temp (°C)	Temperatura del aire de salida
Wpump outlet press (bar)	Presión de salida de la bomba de agua del sistema de enfriamiento
Water inlet temp (°C)	Temperatura del agua que entra al sistema de enfriamiento
Water outlet temp (°C)	Temperatura del agua que sale del sistema de enfriamiento
Wpump power (W)	Potencia consumida por la bomba de agua
Water flow (L/min)	Caudal de agua del sistema de enfriamiento
Oil pump power (W)	Potencia consumida por la bomba de aceite
Oil tank temp (°C)	Temperatura del aceite en el tanque
Gaccx/Gaccy/Gaccz (m/s ²)	Aceleración medida desde el punto de unión entre el compresor y la base
Haccx/Haccy/Haccz (m/s ²)	Aceleración medida desde el perno de la cabeza del compresor
Bearings	Estado de los rodamientos
Wpump	Estado de la bomba de agua
Radiator	Estado del radiador
Exvalve	Estado de la válvula de escape
AC motor	Estado del motor AC

3.2. Diseño de la arquitectura conceptual del sistema de monitorización

En las variables se tuvo en cuenta el tipo de maquinaria ya que, hay muchos tipos de compresores de aire de pistón y el esquema propuesto no debe interferir con agentes externos.

Por lo que, los parámetros medidos pueden ser encontrados en la mayoría de los compresores

de pistón en el mercado. Así mismo, una parte fundamental en el esquema de monitorización es la adquisición de datos o por sus siglas en inglés DAQ. La adquisición de los datos se puede dividir en dos actividades principales, el sensado y la transformación de los datos. En el sensado, los sensores o transductores miden analógicamente los parámetros de interés. Luego, mediante un dispositivo DAQ, se condicionan las señales eliminando ruido y seguidamente, transforma los datos analógicos a digitales para poder ser procesados mediante software. En el apéndice C, se encuentran cuatro tablas informativas en la que se observan los diferentes tipos de sensores y DAQ's para la monitorización de los parámetros vistos en la sección anterior y tres diferentes opciones propuestas según calidad, popularidad y precio aproximado en la industria.

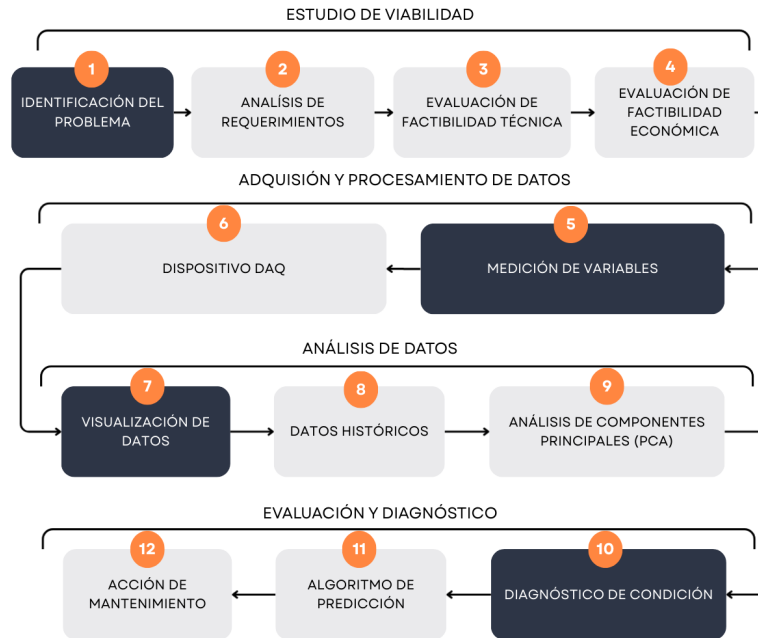
Antes de continuar con la propuesta de diseño, es importante tener en cuenta las limitaciones y restricciones existentes en la solución. Con un plazo de entrega definido y presupuesto limitado, se realizó una planificación adecuada con ayuda del docente para cumplir con el tiempo de desarrollo sin sobrepasar presupuesto. Para ser un diseño que pueda ser implementado debe cumplir también con normativa. Para la realización de este proyecto, se tuvieron en cuenta las normas: EN-13306, EN-13460, UNE-20812, SERIE ISO-55000, ISO-14224, ISO-45001, ISO-12100, ISO-9001, ISO-14001 E ISO-13381. Este conjunto de normas abarca diferentes cualidades y requerimientos para el mantenimiento industrial, gestión de activos e información, seguridad, riesgo, gestión ambiental, gestión de calidad y gestión de la energía. Cabe resaltar la norma ISO 13381-1 del 2015, ya que esta norma se centra en las técnicas y herramientas predictivas que ayudan a prever el rendimiento y la fiabilidad de los sistemas y componentes. Además, proporciona un marco para evaluar la condición de un sistema, pronosticar fallas y tomar decisiones basadas en esos pronósticos. Por lo que, está fuertemente ligada al proyecto y fue parte importante en el diseño de la

solución. Por otra parte, la propuesta de diseño debe ser adaptable a diferentes espacios respetando la infraestructura y funcionamiento del sistema. Es esencial que el diseño de la solución sea claro y accesible para aquellos que la implementen en el futuro, teniendo en cuenta sus habilidades y conocimientos técnicos disponibles. Adicionalmente, se identificó como desafío técnico la alta dimensionalidad de la información, dado que el sistema cuenta con múltiples variables medidas simultáneamente. Este aspecto dificultaba el análisis directo de los datos y requería la implementación de técnicas de reducción de dimensionalidad que permitieran capturar el comportamiento esencial del sistema sin perder información relevante. Las restricciones y limitaciones anteriores garantizan un diseño seguro, confiable, eficiente y de calidad para su implementación. Por lo que, se recomienda al lector interesado en la implementación de este esquema de monitorización tenerlas en cuenta. A continuación, se presenta el diagrama de bloques funcionales del esquema conceptual de monitorización y se describe la función de cada bloque del esquema.

- **Identificación del problema:** Define el objetivo por el cual, el sistema de monitorización será implementado y en que maquinaria será usado. Actividad fundamental para comenzar con este proceso de implementación.
- **Análisis de requerimientos:** Identificada la máquina y su problema de mantenimiento, se analiza su operación a detalle para conocer qué elementos son necesarios para implementar el sistema de monitorización.
- **Evaluación de factibilidad técnica:** Se evalúa mediante criterios, si la implementación del sistema de monitorización es posible en cuanto a disponibilidad de elementos y personal.

Figura 3

Esquema de monitorización propuesto mediante bloques funcionales.



- **Evaluación de factibilidad económica:** Se realiza un análisis de costos estimados y se obtiene la relación costo/beneficio del proyecto.
- **Medición de variables:** Una vez el estudio de viabilidad concluya de manera positiva, se adquieren todos los elementos necesarios. En esta actividad, se miden las variables mediante sensores analógicos por lo que su salida corresponde a señales analógicas.
- **Dispositivo DAQ:** El dispositivo DAQ recibe las señales analógicas y primero las condiciona preparándolas para ser muestreadas digitalmente. Luego, en un proceso llamado aislamiento galvánico se mejora la calidad de la señal. Posteriormente, las señales pasan por un proceso de filtrado donde se eliminan interferencias y ruidos eléctricos. Seguido, se transforma la señal a digital mediante un ADC. Finalmente, se almacenan los datos de

manera permanente mediante un disco duro de estado sólido (HDD o SSD).

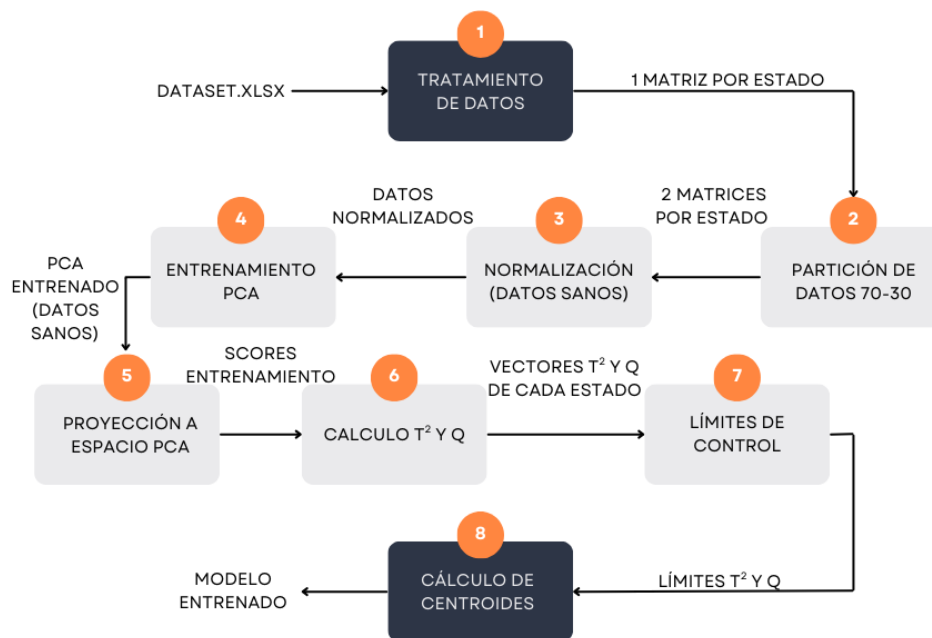
- **Visualización de datos:** Se visualizan los datos en forma de onda y en tiempo real mientras se almacenan. Dependiendo del software utilizado en esta actividad, se puede realizar mediciones de las señales, transformaciones y diferentes tipos de gráficos.
- **Datos históricos:** Una vez visualizados los datos en tiempo real, se comparan con los datos históricos e información técnica de operación del compresor para obtener un conocimiento preliminar del estado actual.
- **Análisis de componentes principales (PCA):** Se realiza un análisis de los componentes principales con datos actuales e históricos para reducir la dimensión de la matriz de los datos y poder observar variables más relevantes, transitorios, desviaciones y comportamiento general del compresor.
- **Diagnóstico de condición:** Se determina la causa de la falla actual o que podría presentarse en un futuro.
- **Algoritmo de predicción:** Una vez obtenido el estado actual del compresor, se aplica el algoritmo de predicción elegido para determinar el tiempo de fallo si se mantiene la condición actual.
- **Acción de mantenimiento:** Luego de obtener el tiempo estimado de fallo o curva de degradación del compresor, se propone o ejecuta la acción de mantenimiento necesaria para una corrección adecuada.

3.3. Entrenamiento del modelo multivariado

A continuación, se expone mediante bloques funcionales, el flujo de la metodología de entrenamiento propuesta para el diseño del modelo multivariado que representa el comportamiento del sistema bajo estudio. Así mismo, se describe de manera estructurada cada bloque funcional, especificando sus respectivas entradas, procesos y salidas, con el fin de facilitar la comprensión del procedimiento de construcción del modelo.

Figura 4

Diagrama de bloques funcionales de la etapa de entrenamiento del modelo.



- **Tratamiento de datos:** Para dar inicio con la metodología, se necesita que los datos obtenidos de los sensores se encuentren de la manera que deseamos, por lo que este bloque es fundamental. En este bloque, se clasifican las muestras por cada uno de los estados y son organizadas en sub-conjuntos compuestos de una matriz por estado de dimensión 200x20

siendo así su señal de salida.

- **Partición de datos 70-30:** En este bloque se realiza la selección del 70 % de los datos de manera aleatoria de cada estado para la etapa de entrenamiento y el 30 % para la etapa de validación.
- **Normalización (Datos sanos):** Los datos saludables de entrenamiento (70 %) son sometidos a un proceso de normalización. Este paso asegura que todas las variables contribuyan de forma equitativa al modelo, evitando que aquellas con mayor magnitud dominen el análisis.
- **Entrenamiento PCA:** En este bloque se ejecuta el entrenamiento del modelo de PCA utilizando únicamente los datos saludables normalizados. En el capítulo de marco conceptual, se describe con más detalle cómo se realiza este proceso. El resultado de este bloque es un modelo matemático que representa el comportamiento normal del sistema de forma compacta y eficiente.
- **Proyección a espacio PCA:** Una vez entrenado el modelo, los datos saludables y los datos de cada condición de fallo (70 %) son proyectados en el espacio de componentes principales. Este bloque transforma las variables originales en coordenadas llamadas scores, que representan la posición de cada muestra en el nuevo espacio latente.
- **Cálculo de T^2 y Q :** En este bloque se calculan los estadísticos Hotelling T^2 y Q (Squared Prediction Error) para cada muestra proyectada mediante sus respectivas fórmulas ya presentadas en el capítulo de marco conceptual. Su salida corresponde a los vectores de estos estadísticos de cada estado de operación.

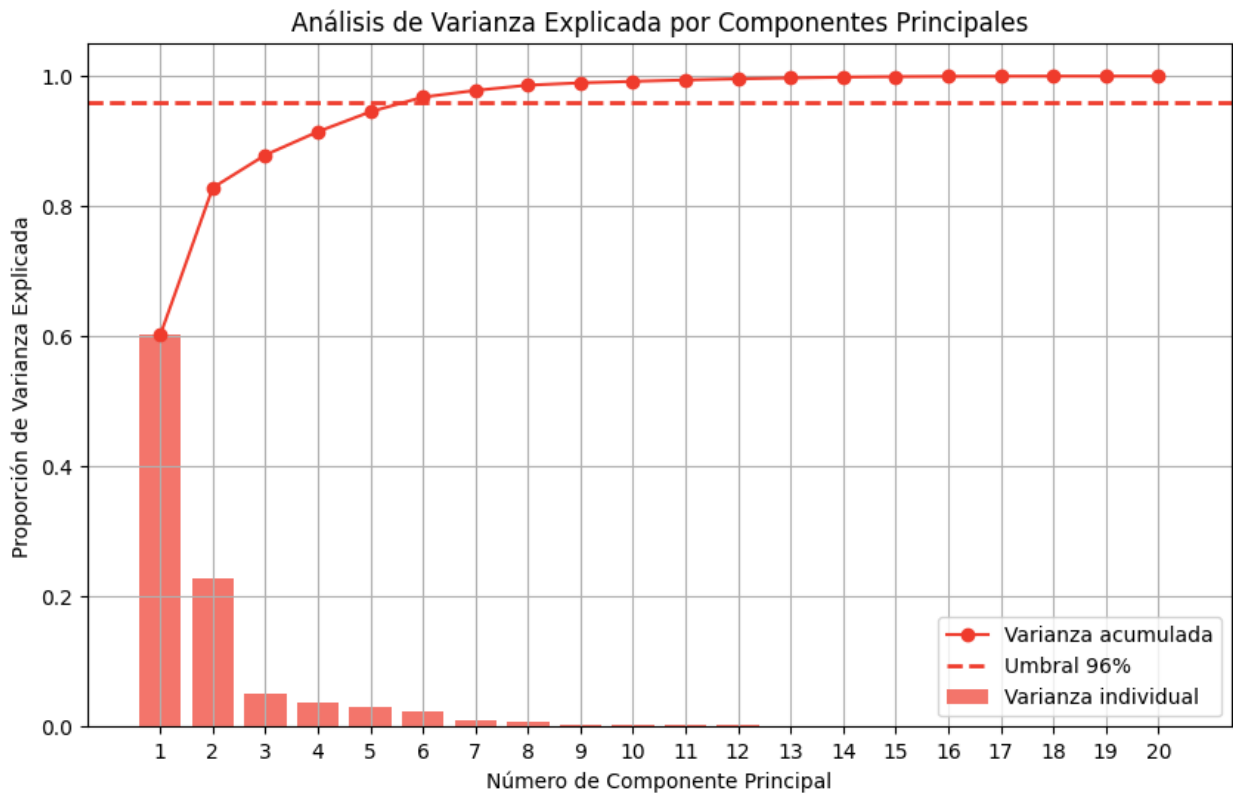
- **Límites de control:** Con base en la distribución de los valores T^2 y Q obtenidos de los datos saludables de entrenamiento, se definen los límites de control estadísticos para un nivel de confianza determinado. Estos límites representan las fronteras entre operación normal y comportamiento anómalo, y constituyen el criterio de decisión para la detección de fallas en la etapa posterior de validación.
- **Cálculo de centroides:** En este bloque se calculan los centroides de cada estado en el plano formado por los estadísticos T^2 y Q . Cada centroide representa el comportamiento promedio de una condición específica y sirve como referencia geométrica para la clasificación posterior de las muestras.

Con el fin de mitigar las limitaciones identificadas, se tomaron decisiones de diseño orientadas a garantizar la validez técnica y metodológica del trabajo. En primer lugar, ante la imposibilidad de obtener datos experimentales propios, se seleccionó un conjunto de datos ampliamente documentado en la literatura, correspondiente a mediciones reales de un compresor industrial, lo cual asegura que el comportamiento analizado sea representativo de un entorno productivo real.

Respecto a la alta dimensionalidad del sistema, se optó por implementar PCA como técnica de reducción de dimensionalidad ya que permite representar el comportamiento del sistema mediante un conjunto reducido de variables no correlacionadas. En nuestro caso, se decidió trabajar solo con 6 componentes principales ya que, en estos se acumulaba aproximadamente el 96% de información según su varianza explicada como se muestra en la figura 6. Asimismo, se decidió estructurar el modelo a partir del estado saludable del sistema, siguiendo el enfoque clásico de monitoreo basado en condición, lo cual permite detectar desviaciones sin depender exclusivamente de grandes volúmenes de datos etiquetados de fallas.

Figura 5

Análisis de varianza explicada por componentes principales.



4. Validación experimental

Con el fin de evaluar la metodología propuesta para el desarrollo del modelo multivariado, fue necesario recurrir a conjuntos de datos reales disponibles en la literatura especializada, dado que no fue posible establecer convenios con empresas para la adquisición directa de mediciones experimentales en campo. Se reconoce como limitación que la validación de la metodología se realizó de manera offline, sin implementación en tiempo real sobre un sistema físico y sin conocer las ventanas de tiempo entre muestras, lo cual restringe la evaluación del desempeño del modelo en condiciones operativas reales y dinámicas.

4.1. Data-set

El data-set o conjunto de datos es uno de los componentes más importantes de este proyecto, por lo cual se llevó a cabo una investigación minuciosa en fuentes académicas y generales con el objetivo de identificar algún conjunto de datos que cumpliera con los criterios mínimos definidos para el desarrollo del proyecto. Estos, se refieren a las mediciones de los principales parámetros de funcionamiento realizadas idealmente a un compresor de aire de pistón mediante sensores de alta precisión y en un entorno controlado con el fin de poder analizarlas. Se llevó a cabo una exploración en plataformas ampliamente reconocidas como Kaggle, UCI Machine Learning Repository, Google Dataset Search y Data.gov, las cuales destacan por facilitar la búsqueda, publicación y acceso a conjuntos de datos de interés comunitario. Como resultado, se identificó un data-set en la plataforma Kaggle que cumplía de manera aceptable con los criterios establecidos para el desarrollo del proyecto.

El conjunto de datos seleccionado contiene un total de mil (1000) muestras de 20 parámetros diferentes y en base a estos datos, se define el estado de algunos de los componentes principales del compresor de aire. A continuación, podemos ver detalladamente los parámetros medidos y los componentes del compresor evaluados. De acuerdo con el autor del data-set Ahmet Okudan, este conjunto de datos ha sido elaborado a partir de mediciones realizadas en el sistema compresor que alimenta la línea de aire de una fábrica. El compresor empleado presenta las siguientes especificaciones: funciona mediante un motor eléctrico de corriente alterna, cuenta con dos pistones, sistema de refrigeración por agua, configuración de una sola etapa, y es capaz de generar hasta 8 bar de presión de aire comprimido.

Por otro lado, las mediciones se realizaron con sensores de alta resolución y un colector de datos de tipo industrial. Adicionalmente, para preparar un conjunto de datos limpio, se eliminaron las líneas de medición con ruido inducido por el cable.

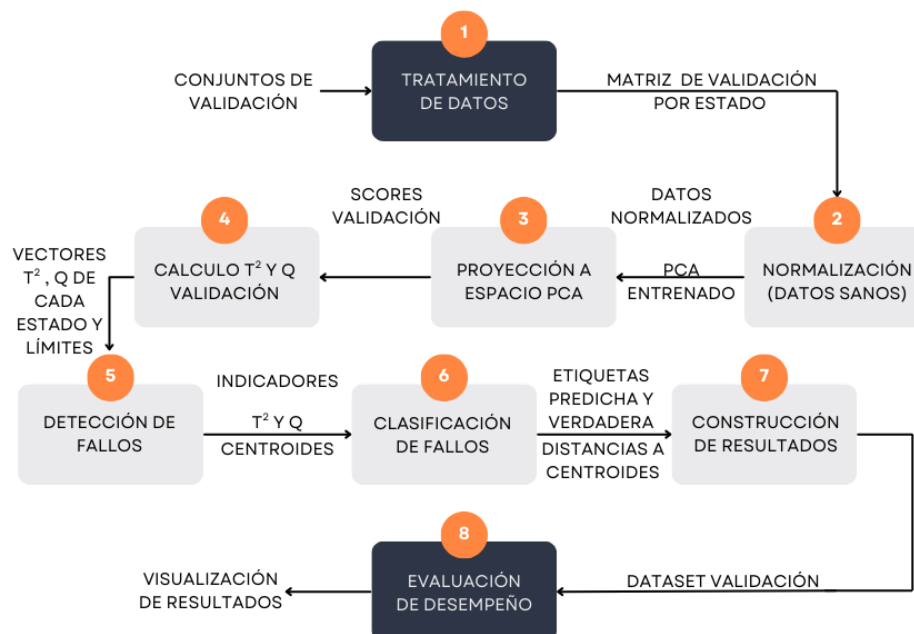
Aunque el conjunto de datos incluye un script en Python orientado al entrenamiento de modelos de aprendizaje para la clasificación del estado de los componentes del compresor, en el presente trabajo se optó por desarrollar una metodología propia basada en el Análisis de Componentes Principales (PCA). Esta decisión se fundamenta en que el objetivo principal de la investigación es el diseño de un esquema de monitorización para mantenimiento predictivo, centrado en la detección de desviaciones del comportamiento normal del sistema, más que en la clasificación directa de fallas específicas. Sin embargo, mediante PCA es posible identificar que variables contribuyen a la falla. Así mismo, permite modelar el estado saludable del compresor y detectar condiciones anómalas mediante los estadísticos T^2 y Q , lo cual resulta más coherente con aplicaciones industriales reales, donde se prioriza la detección temprana de anomalías y no siempre se dispone de grandes volúmenes de datos etiquetados ni se conocen previamente todas las posibles fallas.

4.2. Validación mediante datos disponibles en la literatura

Continuando con el enfoque presentado en la metodología, la etapa de validación se presenta también, mediante bloques funcionales que muestran de manera clara y concisa el procedimiento realizado.

Figura 6

Diagrama de bloques funcionales de la etapa de validación del modelo.



- **Tratamiento de datos:** En este bloque se ingresan los conjuntos de datos correspondientes al 30% reservado para validación de cada condición operativa del sistema. Estos datos no han sido utilizados durante el entrenamiento del modelo, por lo que representan información nueva e independiente. Su función es evaluar la capacidad del modelo para generalizar y reconocer patrones fuera del conjunto de aprendizaje. Tiene como salida una matriz por estado con datos nuevos.

- **Normalización (Datos sanos):** Los datos de validación son normalizados utilizando los mismos parámetros estadísticos (media y desviación estándar) calculados a partir del conjunto saludable de entrenamiento. Este paso es crítico para garantizar la consistencia estadística entre las fases de entrenamiento y validación.
- **Proyección a espacio PCA:** Una vez normalizados, los datos de validación son proyectados en el espacio de componentes principales utilizando el modelo PCA previamente entrenado. De igual manera, que en la etapa de entrenamiento. Su salida corresponde a los scores de validación.
- **Cálculo de T^2 y Q de Validación:** A partir de los scores obtenidos, se calculan los estadísticos Hotelling T^2 y Q (Squared Prediction Error) para cada muestra de validación. Ambos indicadores permiten evaluar el grado de desviación respecto al comportamiento normal.
- **Detección de fallos:** Los valores de T^2 y Q obtenidos en la validación son comparados con los límites de control establecidos durante la etapa de entrenamiento y visualmente con las agrupaciones de los datos saludables. Esta comparación permite determinar si una muestra se encuentra dentro de los rangos normales de operación o si presenta un comportamiento anómalo. En este bloque se materializa el proceso de detección de fallas, identificando desviaciones significativas del estado saludable mediante las gráficas de los estadísticos T^2 y Q.
- **Clasificación de fallos:** Para cada muestra validada, se calcula la distancia euclidiana en el plano (T^2 , Q) respecto a los centroides representativos de cada condición (saludable,

rodamientos, bomba, radiador y válvulas). Este bloque traduce la desviación estadística en una medida geométrica de similitud entre la muestra y cada tipo de fallo. Con base en las distancias calculadas, cada muestra es asignada a la condición cuyo centroide se encuentre más cercano. Este criterio de mínima distancia permite realizar la clasificación automática del tipo de fallo, asociando el patrón observado con la condición operativa más probable. En este punto, el sistema no solo detecta que existe una anomalía, sino que también identifica su origen más probable.

- **Construcción de resultados:** En este bloque se organiza la información de cada muestra validada en hojas de cálculo de excel con una estructura tabular que incluye: índice de muestra, etiqueta real, etiqueta predicha, valores de T^2 , Q y distancias a cada centroide. Esta tabla constituye la base para el análisis cuantitativo del desempeño del modelo y permite rastrear individualmente cada decisión de clasificación.

- **Evaluación de desempeño:** A partir de las etiquetas reales y predichas, se construye la matriz de confusión, la cual resume el número de aciertos y errores por cada condición. Esta herramienta es fundamental para evaluar la capacidad del modelo de diferenciar entre los distintos tipos de fallas y el estado saludable, permitiendo identificar posibles confusiones entre condiciones similares. Finalmente, se generan representaciones gráficas mostradas en el siguiente capítulo. Estas visualizaciones facilitan la interpretación física de los resultados, permitiendo observar la separación entre condiciones, la dispersión de los datos y la efectividad del modelo para discriminar entre estados operativos.

Este flujo representa la implementación práctica del modelo entrenado sobre datos no vistos, cerrando el ciclo de monitoreo inteligente que conecta con el enfoque de mantenimiento predictivo.

A partir de los resultados obtenidos y de las limitaciones identificadas, se reconocen diversas oportunidades de mejora para trabajos futuros. En primer lugar, se propone la implementación de la metodología en un entorno industrial real, integrando sensores, sistemas de adquisición de datos y plataformas de procesamiento en tiempo real, con el fin de validar el desempeño del modelo bajo condiciones operativas dinámicas.

Adicionalmente, se plantea como línea de trabajo futuro la integración del esquema de monitorización con sistemas de gestión de mantenimiento asistido por computador (CMMS), de manera que las alertas generadas por los estadísticos T^2 y Q puedan traducirse automáticamente en órdenes de mantenimiento.

Otra oportunidad de mejora consiste en la evaluación de técnicas híbridas que combinen el enfoque estadístico multivariado con algoritmos de aprendizaje automático, con el fin de fortalecer la capacidad de diagnóstico y clasificación de fallas específicas. Finalmente, se sugiere ampliar el conjunto de variables monitorizadas, incorporando señales adicionales como análisis de aceite, consumo energético detallado y variables ambientales, para enriquecer el modelo y aumentar su sensibilidad frente a más condiciones de fallo.

5. Análisis de resultados

En este capítulo se exponen los resultados obtenidos durante el desarrollo del proyecto. Se realiza un análisis de las gráficas y las matrices de confusión obtenidas, comparándolas con los objetivos planteados al inicio. Entre los resultados presentados se incluyen las gráficas en el espacio de PCA, las gráficas de los estadísticos T^2 y Q , la matriz de confusión y se realiza la comparación de los resultados obtenidos entre el conjunto de muestras completo y su última cuarta parte. Finalmente, se discuten los valores alcanzados en las métricas de desempeño.

5.1. Proyección a espacio PCA

A continuación, se presentan las gráficas de PC1 vs PC2 del conjunto de muestras completo y solo la última cuarta parte. Representa cada muestra del sistema proyectada en las dos componentes de mayor variabilidad. En otras palabras, es una representación bidimensional del comportamiento del compresor.

Al comparar ambas gráficas, se evidencia una diferencia notable de solapamiento entre los estados. Al analizar el conjunto de datos completo, estado por estado, se observó que aproximadamente las últimas 50 muestras presentan un comportamiento diferenciado, alejándose más de las muestras sanas. Este comportamiento justificó el análisis independiente de dicho subconjunto. Si bien la separación entre estados mejora, aún se identifica un leve solapamiento entre las condiciones de rodamientos ruidosos y válvulas sucias con respecto al estado saludable. Este fenómeno puede atribuirse a que las variaciones de estas fallas son sutiles y generan mediciones similares, representando un riesgo menor en el sistema en comparación con las otras fallas.

Figura 7

PC1 vs PC2 (Conjunto de muestras completo).


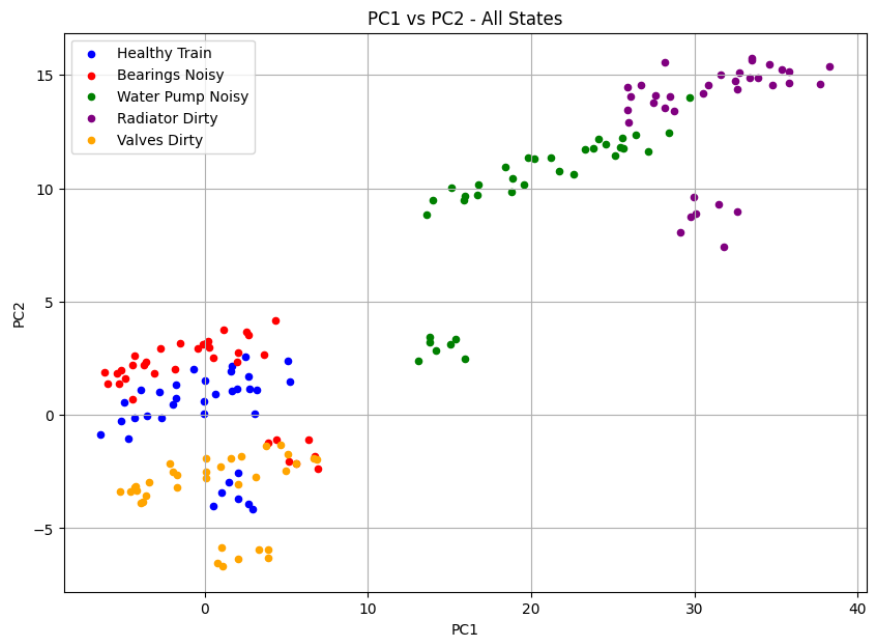


Figura 8

PC1 vs PC2 (Conjunto de últimas 50 muestras).

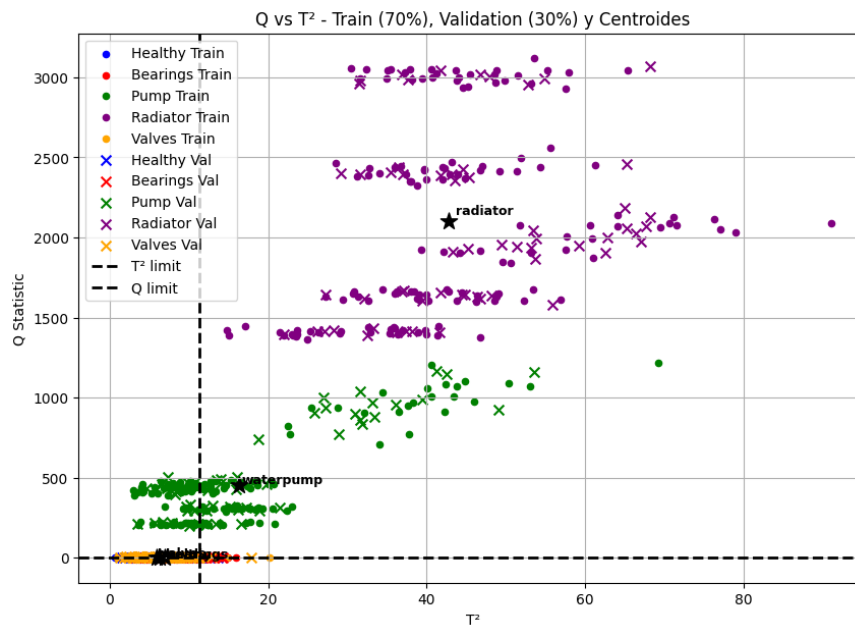


5.2. Detección de fallos mediante Q vs T^2

A continuación, se muestra de forma gráfica cómo los estadísticos Q y T^2 permiten identificar fallos de manera visual, facilitando su interpretación más allá del análisis matemático. Las figuras 9 y 10, confirman el comportamiento observado en el espacio PCA, pero mostrando una mayor claridad en la separación de los estados. Al analizar el conjunto completo, las mismas fallas permanecen cercanas al estado saludable, aunque sus centroides se ubiquen fuera de los límites.

Figura 9


Gráfica Q vs T^2 de todos los estados (Conjunto de muestras completo).



En contraste, al analizar solo las últimas 50 muestras de cada estado (figuras 11 y 12), se obtiene una detección más clara y definida de las fallas, lo que sugiere la presencia de un régimen transitorio en el cual la severidad de la falla aumenta progresivamente. No obstante, la falta de información sobre la frecuencia de muestreo impide caracterizar con precisión esta evolución temporal.

Figura 10

Gráfica Q vs T^2 de todos los estados (Conjunto de muestras completo) (Acercamiento).



5.3. Evaluación de desempeño del clasificador

La evaluación del desempeño se realizó mediante métricas estándar de clasificación. Las Tablas 2 y 3 evidencian que el desempeño del clasificador dependió considerablemente de la representatividad del conjunto de datos utilizado. La diferencia en la exactitud global indica que el modelo responde mejor cuando las fallas son más evidentes en el espacio multivariado definido por los estadísticos Q y T^2 . Así mismo, en las matrices de confusión (Figuras 13 y 14) podemos observar con datos, la mejoría notable entre ambos conjuntos representada en las gráficas anteriores. El reporte de clasificación del conjunto de datos completo expone que el modelo promedió un acierto del 75% de las predicciones (precision) y detectó el 73% de las fallas reales (recall), obteniendo una exactitud global del 73% (accuracy). Mientras que, para el conjunto de datos con las últimas 50 muestras, el modelo aumento positivamente un 20% en cada una de las métricas.

Figura 11

Gráfica Q vs T^2 de todos los estados (Conjunto de últimas 50 muestras).




Figura 12

Gráfica Q vs T^2 de todos los estados (Conjunto de últimas 50 muestras) (Acercamiento).

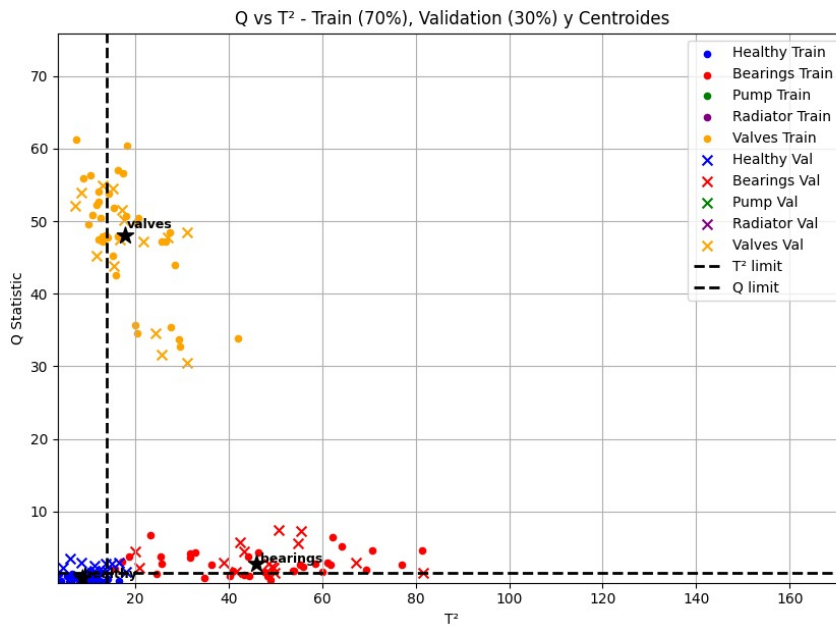


Figura 13

Matriz de confusión (Conjunto de muestras completo).




Figura 14

Matriz de confusión (Conjunto de últimas 50 muestras).




Tabla 2*Reporte de clasificación (Conjunto de muestras completo).*

Condition	Precision	Recall	F1-score	Support
Bearings	0.49	0.58	0.53	60
Healthy	0.63	0.65	0.64	60
Radiator	1.00	1.00	1.00	60
Valves	0.62	0.58	0.60	60
Waterpump	1.00	0.63	0.91	60
Accuracy		0.73		300
Macro avg	0.75	0.73	0.74	300
Weighted avg	0.75	0.73	0.74	300

Nota. Métricas de desempeño del modelo evaluado sobre el conjunto completo de datos.

Tabla 3*Reporte de clasificación (Conjunto de últimas 50 muestras)*

Condition	Precision	Recall	F1-score	Support
Bearings	1.00	0.87	0.93	15
Healthy	0.88	1.00	0.94	15
Radiator	1.00	1.00	1.00	15
Valves	0.83	1.00	0.91	15
Waterpump	1.00	0.80	0.89	15
Accuracy		0.93		75
Macro avg	0.94	0.93	0.93	75
Weighted avg	0.94	0.93	0.93	75

Nota. Métricas de desempeño del modelo evaluado sobre las últimas 50 muestras del conjunto de datos.

6. Conclusiones

El esquema de monitorización propuesto basado en PCA cumplió con el objetivo de detectar y clasificar fallas recurrentes en compresores de aire de pistón. El modelo alcanzó una efectividad aceptable del 93 % para un conjunto de muestras diferenciales, lo que valida la elección de PCA como una técnica adecuada para la implementación de mantenimiento predictivo.

Las proyecciones en el espacio PCA y la gráfica de Q vs T^2 correspondientes al conjunto de las últimas 50 muestras presentan una separación clara entre los estados de bomba de agua defectuosa, radiador sucio y condición saludable. Esto se debe a que las variables fuertemente asociadas a estos estados de falla, como el caudal de agua y la temperatura interna, presentan variaciones considerables cuando la falla está presente. En contraste, en los estados de rodamientos ruidosos y válvulas sucias, las variaciones de algunas variables, como las vibraciones y el nivel de ruido, son menos pronunciadas. No obstante, los resultados deficientes obtenidos con el conjunto de muestras completo, demuestra falta de robustez en el modelo. Exponiendo así, una posibilidad de mejora en cuanto a la clasificación en estados claramente identificados.

El comportamiento observado en las proyecciones en el espacio PCA correspondientes a las últimas 50 muestras de cada estado evidencia un desplazamiento más pronunciado desde la región asociada al estado saludable hacia zonas de falla, lo que sugiere la presencia de un régimen transitorio en el cual la severidad de la falla aumenta de manera progresiva. Este comportamiento permitiría explicar, de forma preliminar, las diferencias observadas en los resultados obtenidos a partir de ambos conjuntos de datos.

El trabajo demuestra que un esquema relativamente de bajo presupuesto (sensores + DAQ + PCA + T²/Q) puede proporcionar una herramienta funcional de soporte para decisiones de mantenimiento predictivo. Asimismo, aporta un diseño de arquitectura y criterios de instrumentación para implementaciones industriales.

La recolección de datos estuvo limitada por la imposibilidad de obtener mediciones propias. Asimismo, la ausencia de información sobre la frecuencia de muestreo en el conjunto de muestras encontrado restringió la evaluación en tiempo real y la detección anticipada de fallas.

7. Recomendaciones y trabajo futuro

La implementación y validación del modelo en tiempo real y en un entorno industrial, garantizará evaluar de forma más realista la capacidad del modelo para detectar, clasificar y finalmente anticipar fallos en el compresor de aire.

Para mejorar la robustez del modelo, se sugiere incorporar más variables de medición en el conjunto de datos. De esta manera, aumentaría la sensibilidad frente a fallas leves y mejoraría el desempeño en el reporte de clasificación.

Un camino prometedor consiste en combinar PCA con métodos supervisados o de aprendizaje profundo como redes neuronales, lo que impactaría positivamente en la clasificación de estados de falla y en reducción de falsos positivos. Este enfoque es relevante, viable y ampliamente adoptado en la literatura reciente, lo que facilita su implementación y comparación.

Como evolución natural del proyecto, se recomienda desarrollar una versión del sistema de monitorización sobre hardware embebido o plataformas IoT industriales. Esto abriría la posibilidad de transmitir datos en línea, generar alertas automáticas y facilitar la toma de decisiones en mantenimiento.

En futuros desarrollos debe considerarse la seguridad de los datos industriales, la confiabilidad del sistema y el impacto de decisiones automatizadas sobre la operación de los equipos. Además, es importante garantizar que el sistema funcione como una herramienta de apoyo al personal técnico y no como un reemplazo de la supervisión humana.

Referencias

- Ahmed, M., Gu, F., y Ball, A. (2011, jul). Feature selection and fault classification of reciprocating compressors using a genetic algorithm and a probabilistic neural network. *Journal of Physics: Conference Series*, 305(1), 012112. doi: 10.1088/1742-6596/305/1/012112
- Aminzadeh, A., Sattarpanah Karganroudi, S., Majidi, S., Dabompre, C., Azaiez, K., Mitride, C., y Sénéchal, E. (2025). A machine learning implementation to predictive maintenance and monitoring of industrial compressors. *Sensors*, 25(4). doi: 10.3390/s25041006
- Aravinth, S., Rajesh Kanna, K., y Sugumaran, V. (2016, diciembre). Air compressor fault diagnosis through vibration signals using statistical features and j48 algorithms. *Indian Journal of Science and Technology*, 9(47). doi: 10.17485/ijst/2016/v9i47/107912
- Cerrada, M., Macancela, J.-C., Cabrera, D., Estupiñan, E., Sánchez, R.-V., y Medina, R. (2020). Reciprocating compressor multi-fault classification using symbolic dynamics and complex correlation measure. *Applied Sciences*, 10(7). doi: 10.3390/app10072512
- Ciobotaru, A., Corches, C., Gota, D., y Miclea, L. (2025). An explainable deep learning-based predictive maintenance solution for air compressor condition monitoring. *Sensors*, 25(18). doi: 10.3390/s25185797
- Deloitte, A. I. (2022). *Predictive maintenance taking pro-active measures based on advanced data analytics to predict and avoid machine failure*. Descargado de <https://www.github.org/resources/publications/predictive>

-maintenance-taking-proactive-measures-based-on-advanced-data
-analytics-to-predict-and-avoid-machine-failure/

Dwivedi, P., Khan, Z., Ansari, H., Chand, J., Singh, M. K., Sagheer, T., ... Abbas, S. H. (2025).

Predictive maintenance and monitoring of industrial compressors using machine learning: A proactive approach. *Metallurgical and Materials Engineering*, 31, (3):372-81. doi: <https://doi.org/10.63278/1387>

Fractal. (s.f.). *Falta de mantenimiento en máquinas genera pérdidas de 2 mdp al año*. Descargado de <https://mexicoindustry.com/noticia/falta-de-mantenimiento-en-maquinas-genera-perdidas-de-2-mdp-al-ano> (Accedido: 2024-03-26)

González-Sánchez, R., Settembre-Blundo, D., Ferrari, A. M., y García-Muiña, F. E. (2020). Main dimensions in the building of the circular supply chain: A literature review. *Sustainability*, 12(6), 2459. doi: <https://doi.org/10.3390/su12062459>

Guo, D., Ge, W., Li, B., y Gao, J. (2023). Identification of air compressor faults based on vit and mel spectrogram. En *2023 2nd international conference on robotics, artificial intelligence and intelligent control (raiiic)* (p. 246-251). doi: 10.1109/RAIIC59453.2023.10281191

James Li, C., y Yu, X. (1995). High pressure air compressor valve fault diagnosis using feed-forward neural networks. *Mechanical Systems and Signal Processing*, 9(5), 527-536. doi: <https://doi.org/10.1006/mssp.1995.0040>

Jardine, A., Lin, D., y Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20, 1483-1510. (Accessed: 2025-03-25) doi: <https://doi.org/10.1016/j.ymsp.2005.09.012>

- Jolliffe, I., y Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philos Trans A Math Phys Eng Sci.* (Accessed: 2025-07-10) doi: 10.1098/rsta.2015.0202
- Keerqinhu, Qi, G., Tsai, W.-T., Hong, Y., Wang, W., Hou, G., y Zhu, Z. (2016). Fault-diagnosis for reciprocating compressors using big data. En *2016 ieee second international conference on big data computing service and applications (bigdataservice)* (p. 72-81). doi: 10.1109/BigDataService.2016.27
- Ketelaere, B. D., Hubert, M., y Schmitt, E. (2015). Overview of pca-based statistical process-monitoring methods for time-dependent, high-dimensional data. *Journal of Quality Technology*, 47(4), 318–335. doi: 10.1080/00224065.2015.11918137
- Kumar, A. (2025). Research overview and prospect in condition monitoring of compressors. *Expert Systems with Applications*, 277, 127284. (Accessed: 2025-03-25) doi: <https://doi.org/10.1016/j.eswa.2025.127284>
- Kutz, M. (2014). *Mechanical engineers' handbook*. doi: 10.1002/9781118985960
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., y Siegel, D. (2014). Prognostics and health management design for rotary machinery systems—reviews, methodology and applications. *Mechanical Systems and Signal Processing*, 42, 314-334. (Accessed: 2025-03-25) doi: <https://doi.org/10.1016/j.ymsp.2013.06.004>
- Lv, Q., Cai, L., Yu, X., Ma, H., Li, Y., y Shu, Y. (2022). An automatic fault diagnosis method for the reciprocating compressor based on hmt and ann. *Applied Sciences*, 12(10). doi: 10.3390/app12105182
- Mobley, K. (2002). *An introduction to predictive maintenance* (2nd ed.). Butterworth-Heinemann.

- Montgomery, D. C., Peck, E. A., y Vining, G. G. (2019). *Introduction to linear regression analysis* (6.^a ed.). Hoboken, NJ: Wiley.
- Nambiar, A., S., N. V., S., A., V., S., Ramteke, S. M., y Marian, M. (2024). Prediction of air compressor faults with feature fusion and machine learning. *Knowledge-Based Systems*, 304, 112519. doi: <https://doi.org/10.1016/j.knosys.2024.112519>
- Narváez, F. (2018). *Eficiencia energética en sistemas de aire comprimido*. (Bogotá)
- Prashanth, K., y Elangovan, M. (2019, nov). Vibration based fault monitoring of a compressor using tree-based algorithms. *IOP Conference Series: Materials Science and Engineering*, 577(1), 012116. doi: 10.1088/1757-899X/577/1/012116
- Qin, Q., Jiang, Z.-N., Feng, K., y He, W. (2012). A novel scheme for fault detection of reciprocating compressor valves based on basis pursuit, wave matching and support vector machine. *Measurement*, 45(5), 897-908. doi: <https://doi.org/10.1016/j.measurement.2012.02.005>
- S, A., y V, S. (2023). Prediction of air compressor condition using vibration signals and machine learning algorithms. *Journal of Vibration and Control*, 29(5-6), 1342-1351. doi: 10.1177/10775463211062330
- Sivakumar, A., y Vaithyanathan, S. (2021, jan). Vibration based data analysis of single acting compressor through condition monitoring and multilayer perceptron – a machine learning classifier. *IOP Conference Series: Materials Science and Engineering*, 1012(1), 012032. doi: 10.1088/1757-899X/1012/1/012032
- Srivatsan, B., Venkatesh, S. N., Aravinth, S., Sugumaran, V., Dhanraj, J. A., Solomon, J. M., y Vaidhyathan, R. M. (2024). Fault diagnosis of air compressors using transfer lear-

- ning: A comparative study of pre-trained networks and hyperparameter optimization. *Journal of Low Frequency Noise, Vibration and Active Control*, 43(4), 1877-1894. doi: 10.1177/14613484241273652
- Tran, V. T., AlThobiani, F., y Ball, A. (2014). An approach to fault diagnosis of reciprocating compressor valves using teager–kaiser energy operator and deep belief networks. *Expert Systems with Applications*, 41(9), 4113-4122. doi: <https://doi.org/10.1016/j.eswa.2013.12.026>
- Tran, V. T., AlThobiani, F., Tinga, T., Ball, A., y Niu, G. (2018). Single and combined fault diagnosis of reciprocating compressor valves using a hybrid deep belief network. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 232(20), 3767-3780. doi: 10.1177/0954406217740929
- Wang, F., Song, L., Zhang, L., y Li, H. (2010). Fault diagnosis for reciprocating air compressor valve using p-v indicator diagram and svm. En *2010 third international symposium on information science and engineering* (p. 255-258). doi: 10.1109/ISISE.2010.91
- Wang, H., Dong, F., Zhou, X., Wang, H., Zhu, X., Song, L., y Guo, Q. (2019). Fault diagnosis of reciprocating compressor using component estimating empirical mode decomposition and de-dimension template with double-loop correction algorithm. *IEEE Access*, 7, 90630-90639. doi: 10.1109/ACCESS.2019.2925836
- Wang, Y., Xue, C., Jia, X., y Peng, X. (2015). Fault diagnosis of reciprocating compressor valve with the method integrating acoustic emission signal and simulated valve motion. *Mechanical Systems and Signal Processing*, 56-57, 197-212. doi: <https://doi.org/10.1016/j.ymsp.2014.11.002>

Wu, W., Li, C., Zhu, Z., Li, X., Zhang, Y., Zhang, J., ... Wang, B. (2023). A new method for reciprocating compressor fault diagnosis based on indicator diagram feature extraction. *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, 237(6), 1337-1347. doi: 10.1177/09576509231161855

Zhai, S., Achatz, S., Groher, M., Permadi, J., y Reinhart, G. (2020). An empirical expert study on the status quo and potential of predictive maintenance in industry. *2020 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC), Beijing, China*, 125-130. (Accessed: 2026-01-03) doi: 10.1109/SDPC49476.2020.9353177

Zhang, W., Yang, D., y Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey*, 13, 2213-2227. (Accessed: 2025-03-25) doi: 10.1109/JSYST.2019.2905565

Apéndice A: Repositorio en GitHub (Código)

Se ha establecido un *Repositorio en GitHub*, con el propósito de facilitar el acceso académico y fomentar la colaboración en el proyecto. Este repositorio incluye el código principal del esquema de monitorización con el modelo multivariado para la detección y clasificación de fallas. Esto promueve el aprendizaje y alienta a otros investigadores y estudiantes a contribuir y mejorar el sistema, ampliando así su impacto en la comunidad académica.

Apéndice B: Conjunto de datos (Data-set)

En este anexo se presenta el conjunto de datos utilizado para el desarrollo y validación del sistema de detección y clasificación de fallos, el cual fue obtenido de una fuente pública en la plataforma kaggle. Este *Data-set* contiene mediciones reales en un compresor industrial de pistón, accionado por motor eléctrico de corriente alterna, enfriado por agua y con capacidad de hasta 8 bar. Las mediciones se realizaron con sensores de alta resolución y equipos industriales. Además, se eliminaron las señales afectadas por ruido para garantizar la calidad de los datos.

Apéndice C: Dispositivos propuestos para la implementación del sistema

El presente anexo reúne el conjunto de sensores considerados para una posible implementación del sistema de monitorización propuesto, organizados según su rango de precio en categorías de bajo, medio y alto costo. Para cada sensor se especifica el tipo, la marca, el modelo y el precio de referencia, con el fin de proporcionar un panorama comparativo que facilite la toma de decisiones en función de criterios técnicos y económicos.

Tabla 4

Dispositivos DAQ propuestos.

Categoría	Marca	Modelo	Precio (USD)
Precio bajo	National Instruments	USB-6009	90
Precio medio	Dewesoft	Obsidian	900
Precio alto	Keysight	DAQ970A	3000

Tabla 5

Sensores propuestos de precio bajo.

Tipo de sensor	Marca	Modelo	Precio (USD)
CKP/PMS	Bosch	0232103033	26
Vatímetro / Medidor de potencia	Eastron	SDM120	35
Transductor de torque	FUTEK	Small Action TS	178
Transductor de presión / Manómetro	WIKA	111.10	24
Caudalímetro / MAF	Bosch	0280212025	63
Sonómetro	Extech	407730	95
Sensor de temperatura	Murata	NTC Thermistor	5
Sensor de vibraciones / Acelerómetro	Analog Devices	ADXL345	20

Es importante resaltar que, en la categoría de precio alto y medio se obtienen mejores resultados en cuanto a precisión y diversidad de funciones. Mientras que, en la categoría de precio bajo,

Tabla 6*Sensores propuestos de precio medio.*

Tipo de sensor	Marca	Modelo	Precio (USD)
CKP/PMS	Delphi	SS11019	162
Vatímetro / Medidor de potencia	Schneider	iEM3000	180–320
Transductor de torque	FUTEK	TFF400	250–750
Transductor de presión / Manómetro	Yokogawa	TBD 4–20 mA	80–180
Caudalímetro / MAF	Bosch	0280212025	380
Sonómetro	Extech	407730	100
Sensor de temperatura	Omega	K-type Thermocouple	20–50
Sensor de vibraciones / Acelerómetro	PCB	352C33	20–50

Tabla 7*Sensores propuestos de precio alto.*

Tipo de sensor	Marca	Modelo	Precio (USD)
CKP/PMS	Delphi	050906433	180
Vatímetro / Medidor de potencia	Fluke	1735	1700
Transductor de torque	HBM	T10/T12	1000–5000
Transductor de presión / Manómetro	Rosemount	3051	800–4000
Caudalímetro / MAF	Yokogawa	Coriolis	2000–8000
Sonómetro	Brüel & Kjær	2250	6000–9000
Sensor de temperatura	Omega	RTD PT100 IND	160–500
Sensor de vibraciones / Acelerómetro	PCB	621C40	500–2000

las funciones son limitadas y la precisión de estos dispositivos cuentan con un mayor margen de error. En cuanto al software de análisis y visualización de datos, se recomienda utilizar el software proporcionado por la misma marca del dispositivo DAQ. De esta manera, se garantiza un sistema con mejor comunicación y amigable para el usuario.

Apéndice D: Descripción de variables monitorizadas

En este anexo se presenta una breve descripción de cada una de las variables monitorizadas y los componentes analizados en el conjunto de datos utilizado en este proyecto.

- **Rpm:** Permite conocer la velocidad de rotación del motor y, por tanto, la frecuencia de trabajo del compresor. Cambios anómalos pueden indicar deslizamientos en correas, fallos en el motor o sobrecarga mecánica.
- **Motor power:** Refleja la potencia consumida por el motor eléctrico. Un aumento repentino puede sugerir fricción excesiva, obstrucciones en las válvulas o un mal funcionamiento del sistema de lubricación.
- **Torque:** Indica el esfuerzo mecánico aplicado por el motor. Su monitoreo permite detectar desequilibrios, sobre esfuerzos o desgaste en componentes del tren mecánico.
- **Outlet pressure bar:** Corresponde a la presión del aire comprimido en la salida. Variaciones inusuales pueden señalar fugas, fallas en las válvulas o problemas de sellado en los cilindros.
- **Air flow:** Mide el caudal de aire comprimido entregado por el sistema. Su disminución puede deberse a pérdidas por fugas o a una eficiencia volumétrica reducida del pistón.
- **Noise db:** El nivel de ruido refleja el estado mecánico del compresor. Un aumento puede anticipar desgaste de cojinetes, holguras en componentes móviles o desalineación.
- **Outlet temp:** La temperatura del aire de salida permite evaluar la eficiencia de compresión y la efectividad de la refrigeración. Temperaturas altas pueden indicar sobrecalentamiento.

miento, baja lubricación o deficiencias en el sistema de enfriamiento.

- **W pump outlet press:** Controla la presión del sistema de enfriamiento por agua. Disminuciones podrían reflejar fugas o fallas en la bomba de agua.
- **Water inlet temp:** Indica la temperatura del agua que entra al sistema de refrigeración. Es esencial para determinar la eficiencia térmica del proceso de enfriamiento.
- **Water outlet temp:** Mide la temperatura del agua que sale del sistema. Un incremento excesivo puede anticipar sobrecarga térmica o reducción del caudal de agua.
- **W pump power:** Señala la potencia consumida por la bomba de agua. Aumentos anormales pueden asociarse con desgaste del impulsor o bloqueos en el sistema de circulación.
- **Water flow:** Determina el caudal del sistema de refrigeración. Su reducción puede indicar obstrucciones, fugas o fallas de la bomba, afectando directamente la disipación de calor.
- **Oil pump power:** Controla la potencia consumida por la bomba de aceite. Incrementos pueden indicar alta viscosidad del aceite o resistencia por suciedad en conductos.
- **Oil tank temp:** Mide la temperatura del aceite en el tanque. Valores altos pueden advertir pérdida de capacidad lubricante o sobrecalentamiento del compresor.
- **Gaccx/Gaccy/Gaccz:** Representan la aceleración medida en la base del compresor. Permiten detectar vibraciones anómalas causadas por desalineación, desequilibrio o fallos estructurales.

- **Haccx/Haccy/Haccz:** Aceleraciones medidas en la cabeza del compresor. Su análisis ayuda a identificar problemas en el pistón o en la biela, como golpes o desbalance dinámico.
- **Bearings (Rodamientos):** Estado de los rodamientos. Su monitoreo es clave para anticipar desgaste, fricción excesiva o inicio de falla por fatiga.
- **W pump (Bomba de agua):** Estado operativo de la bomba de agua. Permite detectar interrupciones en el sistema de enfriamiento.
- **Radiator (Radiador):** Indica el estado del radiador o intercambiador térmico. Su degradación afecta directamente la eficiencia de enfriamiento del sistema.
- **Ex valve (Válvula de salida):** Estado de la válvula de escape. Una válvula defectuosa puede generar pérdida de presión, aumento de temperatura o baja eficiencia volumétrica.
- **Ac motor (Motor):** Estado del motor principal. Su supervisión permite detectar sobrecargas eléctricas, fallas de aislamiento o interrupciones de funcionamiento.