



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA
CARRERA DE INGENIERÍA MECÁNICA**

**"DETECCIÓN DE FALLOS EN UN COMPRESOR RECIPROCANTE
DE SIMPLE EFECTO DOBLE ETAPA MEDIANTE LA
CONSTRUCCIÓN DE UN MODELO BASADO EN ANÁLISIS DE
COMPONENTES PRINCIPALES A PARTIR DE SEÑALES EN
CONDICIÓN NORMAL"**

Trabajo de titulación previo a la obtención
del título de Ingeniero Mecánico

AUTOR: BRYAN MAURICIO CABRERA SALAZAR

TUTOR: ING. DIEGO ROMAN CABRERA MENDIETA, Ph.D.

Cuenca - Ecuador

2022

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, Bryan Mauricio Cabrera Salazar con documento de identificación N° 0107281180 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 27 de septiembre del 2022

Atentamente,

A handwritten signature in blue ink that reads "Mauricio Cabrera S". The signature is enclosed within a hand-drawn blue oval.

Bryan Mauricio Cabrera Salazar

0107281180

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Yo, Bryan Mauricio Cabrera Salazar con documento de identificación N° 0107281180, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del *Proyecto Técnico: Detección de fallos en un compresor recíprocante de simple efecto doble etapa mediante la construcción de un modelo basado en análisis de componentes principales a partir de señales en condición normal*, el cual ha sido desarrollado para optar por el título de: *Ingeniero Mecánico*, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 27 de septiembre del 2022

Atentamente,




Bryan Mauricio Cabrera Salazar
0107281180

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Diego Roman Cabrera Mendieta con documento de identificación N° 0104028303, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: **DETECCIÓN DE FALLOS EN UN COMPRESOR RECIPROCANTE DE SIMPLE EFECTO DOBLE ETAPA MEDIANTE LA CONSTRUCCIÓN DE UN MODELO BASADO EN ANÁLISIS DE COMPONENTES PRINCIPALES A PARTIR DE SEÑALES EN CONDICIÓN NORMAL**, realizado por Bryan Mauricio Cabrera Salazar con documento de identificación N° 0107281180, obteniendo como resultado final el trabajo de titulación bajo la opción *Proyecto Técnico* que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 27 de septiembre del 2022

Atentamente,



Ing. Diego Roman Cabrera Mendieta Ph.D.

0104028303

DEDICATORIA

Dedicado a mis padres María del Carmen y Manuel Oswaldo.

Dedicado a la memoria de mi abuelo Manuel.

“Nuestras raíces son las mismas y, mientras yo esté en pie, tú también vivirás”

Bryan Mauricio

AGRADECIMIENTOS

En primer lugar me gustaría agradecer al Dr. Diego Cabrera por su ayuda, comprensión y orientación durante el desarrollo del presente proyecto.

Por otro lado me gustaría agradecer a los miembros del Grupo de Investigación y Desarrollo en Tecnologías Industriales (GIDTEC) por su conocimiento y apoyo moral brindado.

En el mismo sentido me gustaría agradecer a todos los miembros del Departamento de Ingeniería Mecánica. Durante mi estadía como estudiante de pregrado, siento que he adquirido una gran cantidad de conocimientos.

Por otra parte me gustaría agradecer a todas las personas que me brindaron su amistad. Soy fiel creyente que la trascendencia del ser humano se basa en las relaciones interpersonales que forjamos a lo largo de nuestra vida, en cierto modo nos ayudan a ver al mundo de manera distinta. Les agradezco mucho ya que cada parte que soy ahora, son ustedes.

En suma les agradezco a mis padres María y Oswaldo por TODO en esta vida. Yo pienso que las relaciones parentales son el pilar fundamental de la vida de cada uno de nosotros. Les agradezco por los valores, la disciplina y la educación inculcados, ya que de esa forma me han impulsado a lograr este objetivo personal.

Y por último, pero no menos importante, le agradezco a Dios omnipotente, omnipresente y omnisciente por haber hecho realidad todo lo que acabo de relatar. Te agradezco lo que haz hecho de mí.

Bryan Mauricio

RESUMEN

Los compresores recíprocos son máquinas altamente utilizadas en las industrias por ser la principal fuente de aire comprimido, es por eso que la aplicación de una estrategia de mantenimiento inadecuada para la detección temprana de fallos conduce al incremento de paros inesperados. La detección de fallos en este tipo de máquinas resulta en la mayoría de los casos compleja, por la dificultad para monitorear en tiempo real los procesos involucrados. Además, en el diagnóstico de fallos se emplea diversas técnicas de modelamiento las cuales requieren de grandes cantidades de datos en condición normal y con fallo, lo que desemboca en altos costos para su adquisición.

En este trabajo, utilizamos PCA (Principal Component Analysis; la sigla se puede traducir como “Análisis de Componentes Principales”) como marco de modelado para un nuevo algoritmo de detección de fallos que explota las ventajas de la prueba de relación de verosimilitud generalizada para mejorar la detección de fallos cuando no se dispone de un modelo de proceso. La característica diferenciadora de este método estadístico radica en que la etapa de modelado solo necesita de datos en condición normal, a diferencia de otros métodos alternativos de aprendizaje automático que requieren de datos en condición normal y con fallo para la misma etapa. La metodología propuesta se aplica a las válvulas de un compresor recíproco.

En un inicio las señales de vibración son adquiridas para diferentes condiciones de fallo, sin embargo, para la etapa del modelado solo se utiliza los datos en condición normal. Luego se efectúa el procesamiento de las señales adquiridas, donde se extraen características en el dominio del tiempo. En una siguiente etapa se entrena al modelo basado en PCA. Luego, GLRT (Generalized Likelihood Ratio Test; la sigla se puede traducir como “Test de Razón de Verosimilitud Generalizada”) se utiliza para establecer los parámetros de una hipótesis compuesta para detectar la presencia o ausencia de un fallo. Para culminar, se implementa y evalúa el modelo de detección de fallos. En síntesis, luego de realizar la experimentación se muestra que la fiabilidad del modelo alcanza el 87% del rendimiento mostrado mediante el área bajo la curva de probabilidad ROC (Receiver Operating Characteristic; la sigla se puede traducir como “Característica Operativa del Receptor”).

ABSTRACT

Reciprocating compressors are highly used machines in industries as they are the main source of compressed air, which is why the application of an inadequate maintenance strategy for early detection of failures leads to an increase in unexpected stoppages. The detection of faults in this type of machine is complex in most cases, due to the difficulty of monitoring the processes involved in real-time. In addition, in the diagnosis of failures, various modeling techniques are used, which require large amounts of data in normal and faulty conditions, which leads to high costs for their acquisition.

In this document, we use PCA (Principal Component Analysis) as a modeling framework for a new failure detection algorithm that exploits the advantages of the generalized likelihood ratio test to improve failure detection when a failure model is not available. The differentiating characteristic of this statistical method is that the modeling stage only needs data in normal conditions, unlike other alternative methods of machine learning that require data in normal and fault conditions for the same stage. The proposed methodology is applied to the valves of a reciprocating compressor.

Initially the vibration signals are acquired for different fault conditions, however, for the modeling stage only the data in normal condition is used. Then, the processing of the acquired signals is carried out, where characteristics are extracted in the time domain. In a next stage, the PCA-based model is trained. Then, GLRT (Generalized Likelihood Ratio Test) is used to set the parameters of a composite hypothesis to detect the presence or absence of a failure. Finally, the fault detection model is implemented and evaluated. In short, after performing the experimentation, it is shown that the reliability of the model reaches 87% of the performance shown by the area under the ROC (Receiver Operating Characteristic) probability curve.

ÍNDICE DE CONTENIDO

SECCIÓN	PÁGINA
DECLARATORIA DE RESPONSABILIDAD Y AUTORÍA	iii
CESIÓN DE DERECHOS DE AUTOR	iv
CERTIFICADO DE DIRECCIÓN	v
DEDICATORIA	vi
AGRADECIMIENTOS	vii
RESUMEN	viii
ABSTRACT	ix
ÍNDICE DE FIGURAS	xi
ÍNDICE DE TABLAS	xii
LISTA DE ACRÓNIMOS	xiii
1 INTRODUCCIÓN	1
1.1 Planteamiento del Problema	3
1.1.1 Antecedentes	3
1.1.2 Importancia y Alcance	6
1.1.3 Delimitación	7
1.2 Objetivos	7
1.2.1 Objetivo General	7
1.2.2 Objetivos Específicos	8
2 MARCO TEÓRICO	9
2.1 Mantenimiento basado en la condición	9
2.2 Monitoreo de la condición	9
2.2.1 Monitoreo de vibraciones	9
2.2.2 Emisiones acústicas	10

2.2.3	Monitoreo de corriente del motor	10
2.2.4	Termografía	10
2.3	Compresores	10
2.3.1	Tipos de compresores	11
2.3.2	Fallos comunes en compresores reciprocantes	11
2.4	Análisis de componentes principales	12
2.5	Detección de fallos mediante pruebas de hipótesis	15
3	METODOLOGÍA PROPUESTA	19
3.1	Adquisición de señales	20
3.1.1	Banco de pruebas para un compresor recíprocante simple efecto doble etapa	20
3.1.2	Sistema de adquisición de señales de vibración	21
3.1.3	Fallos implantados en válvulas	22
3.2	Generación del conjunto de datos	25
3.2.1	Incremento de señales	26
3.2.2	Extracción de características	27
3.2.3	Validación cruzada	29
3.3	Construcción del modelo de detección	29
3.4	Validación del modelo	32
3.5	Sistema de detección de fallos en línea	32
4	ANÁLISIS DE RESULTADOS	34
4.1	Resultados de extracción de características	34
4.2	Resultados del proceso de entrenamiento	35
4.3	Resultados de sistema de detección de fallos en línea	43
	CONCLUSIONES	47
	RECOMENDACIONES Y TRABAJOS FUTUROS	48
	REFERENCIAS	48

ÍNDICE DE FIGURAS

Figura 1	Clasificación de los tipos de compresores según su principio de funcionamiento.	11
Figura 2	Diagrama del método de detección de fallos basado GLRT - PCA.	17
Figura 3	Metodología empleada para la detección de fallos.	19
Figura 4	Banco de pruebas experimentales para compresor	20
Figura 5	Esquema del sistema de adquisición de las señales de vibración. . .	21
Figura 6	Codificación para la identificación de válvulas.	22
Figura 7	Vista superior del cabezote del compresor.	22
Figura 8	Ubicación del acelerómetro en el compresor.	26
Figura 9	División de una señal.	27
Figura 10	Validación cruzada dejando uno fuera.	29
Figura 11	Varianza capturada por cada componente.	30
Figura 12	Curva ROC en modelo basado en PCA.	32
Figura 13	Propuesta de sistema de detección de fallos en línea para compresor reciprocante.	33
Figura 14	División de señal de vibración.	34
Figura 15	Varianza porcentual acumulada por cada componente.	35
Figura 16	Curva ROC para modelo basado en PCA.	36
Figura 17	Sistema de detección de fallos en línea para compresor reciprocante en condición normal.	44
Figura 18	Componentes principales para condición normal.	44
Figura 19	Sistema de detección de fallos en línea para compresor reciprocante en condición en fallo.	45
Figura 20	Componentes principales para condición con fallo.	45

ÍNDICE DE TABLAS

Tabla 1	Detalles de la construcción de los fallos y su localización.	24
Tabla 2	Localización de los fallos en las válvulas del compresor	25
Tabla 3	Ejemplo de matriz de correlación.	27
Tabla 4	Características en el dominio del tiempo	28
Tabla 5	Matriz de correlación de características	37
Tabla 6	Tasa de falsos positivos con nivel de significancia α 0.05	38
Tabla 7	Tasa de falsos positivos con nivel de significancia α 0.01	39
Tabla 8	Tasa de falsos positivos con nivel de significancia α 0.001	40
Tabla 9	Tasa de falsos positivos con nivel de significancia α 0.0136	41
Tabla 10	Media de la tasa de falsos positivos para diferentes tipos de α . . .	43

LISTA DE ACRÓNIMOS

BES	Bomba Eléctrica Sumergible
FFT	Transformada Rápida de Fourier
GIDTEC	Grupo de Investigación y Desarrollo en Tecnologías Industriales
GLRT	Generalized Likelihood Ratio Test
MBC	Mantenimiento Basado en la Condición
PCA	Principal Component Analysis
RNA	Redes Neuronales Artificiales
ROC	Relative Operating Characteristic
VPA	Varianza Porcentual Acumulada

1. INTRODUCCIÓN

Habitualmente el mantenimiento es definido como el conjunto de técnicas empleadas para preservar equipos e instalaciones en las mejores condiciones de operación (García, 2010). La principal función del mantenimiento es mantener operativos a los equipos y garantizar el buen estado de las máquinas a través del tiempo (Mora, 2009).

El mantenimiento industrial es una inversión ya que genera beneficios para la planta física, entre los cuales podemos considerar que garantiza que la producción no sea interrumpida por paros imprevistos; además, previene y evita accidentes laborales aumentando la seguridad de operarios que intervienen en el proceso productivo (Medrano et al., 2017). Generalmente para la gestión del mantenimiento industrial se utiliza planes de mantenimiento que describen la planificación, la programación y evaluación de las tareas de mantenimiento aplicadas a la maquinaria (Bevilacqua y Braglia, 2000).

Evidentemente surge una necesidad de conocer filosofías de mantenimiento que ayuden a prolongar la vida útil de los equipos y reduzcan las paradas no programadas. En consecuencia, las filosofías de mantenimiento más comunes se han clasificado en: mantenimiento correctivo, mantenimiento preventivo y mantenimiento predictivo (Coria et al., 2015).

Dentro de esta última filosofía de mantenimiento predictivo se encuentra el mantenimiento basado en la condición (MBC) que monitorea en tiempo real a un equipo para determinar el mantenimiento que debe emplearse. De igual manera en el MBC se encuentra el monitoreo de la condición el cual mide de forma periódica uno o más variables presentes en la máquina, con el fin de identificar cambios significativos en estas variables que usualmente nos indican fallos (Kothamasu et al., 2006).

Una de las técnicas del monitoreo de la condición es el análisis de vibraciones que detecta anomalías mediante desviaciones en las características de las señales obtenidas de la variable vibración. Sin embargo, al aplicar el monitoreo de vibraciones se necesita disponer de modelos que permitan detectar con precisión y rapidez estas desviaciones (Medrano et al., 2017). Por lo cual, en las últimas décadas se desarrollaron varios modelos de supervisión, las cuales se clasifican en dos categorías: modelos basadas en el proceso y modelos basados en datos (Majdi et al., 2020).

El primer modelo compara las mediciones del proceso con los conocimientos obtenidos

1. INTRODUCCIÓN

a partir de un modelo matemático (Kinnaert, 2003). Por otra parte, el segundo modelo de supervisión busca la disponibilidad de datos históricos obtenidos del proceso sin fallos. Estos datos se utilizan para construir un modelo empírico, que luego se utiliza para detectar fallos en los datos futuros. Los modelos basados en datos incluyen los métodos de regresión de variables latentes, como la regresión de mínimos cuadrados parciales, el análisis de componentes principales, el análisis de componentes independientes, el análisis de variantes canónicas, las redes neuronales, los sistemas difusos, los métodos de reconocimiento de patrones y los métodos basados en máquinas de vectores de apoyo (Majdi et al., 2020).

Los métodos de monitoreo basados en datos, especialmente aquellos que utilizan PCA o sus extensiones, se han utilizado ampliamente en muchas aplicaciones en una amplia gama de industrias, por ejemplo; monitoreo de la calidad del aire, industria química, tratamiento de agua, farmacología, biología y biotecnología, agricultura, salud y muchos otros más (Majdi et al., 2020).

En el trabajo se propone describir la metodología empleada para la construcción de un modelo basado en datos para la detección de fallos en un compresor reciprocante de simple efecto, doble etapa. El presente documento está seccionado de la siguiente forma:

La introducción aborda de forma general la temática que se trata en el proyecto técnico, se muestra la descripción del problema asociado a la detección de fallos en el compresor reciprocante de simple efecto, doble etapa. Así mismo se muestra la importancia y generalidad del problema para el sector industrial.

Además, se presentan los resultados de otras investigaciones o estudios relacionados con la detección de fallos en compresores reciprocantes. Finalmente, se explica la contribución que se pretende alcanzar con el presente proyecto técnico mediante el desarrollo un modelo basado en análisis de componentes principales para la detección de fallos en un compresor reciprocante de simple efecto, doble etapa solamente a partir de señales en condición normal.

El marco teórico contiene la información necesaria para la comprensión de la temática expuesta. Se aborda conceptos sobre mantenimiento basado en la condición, también se explican las diversas técnicas que forman parte del monitoreo de la condición. De modo idéntico se explica la fundamentación teórica relacionada con el compresor reciprocante y finalmente, se aborda el tema central que es el análisis de componentes principales en

conjunto con las pruebas de hipótesis para la detección de fallos.

La metodología propuesta presenta el cómo se llevo a cabo la solución a la problemática planteada. En este capítulo se describe al sistema de adquisición de señales de vibración útiles para el proceso de entrenamiento e inferencia del modelo basado en datos para la detección de fallos. De la misma forma se menciona características de la máquina de estudio, sus principales fallos emulados en el laboratorio del GIDTEC.

Posteriormente se presenta la metodología para la detección de fallos mediante la construcción de un modelo basado en análisis de componentes principales a partir de señales en condición normal. En esta sección específicamente se muestra cómo se realizó la extracción de características a las señales colectadas, además cómo se incremento las señales para poder éstas ingresar a las fases de entrenamiento y validación.

Subsecuente se explica mediante dos algoritmos cómo funciona la metodología para la detección de fallos en el compresor. Así mismo se muestra cómo evaluar la metodología propuesta mediante el análisis de la curva ROC. Finalmente el capítulo cierra con las etapas y requerimiento del sistema de detección en línea.

Finalmente se realiza un análisis de resultados donde se puede apreciar como cada uno de los resultados permitieron cumplir con cada uno de los objetivos planteados. Desde la fase de extracción de características hasta el sistema de detección de fallos en línea. Finalmente, se presentan las conclusiones y recomendaciones acorde a los objetivos planteados y una propuesta para trabajos futuros.

1.1. Planteamiento del Problema

1.1.1. Antecedentes

En el sector industrial se considera que el aire comprimido es un recurso muy importante para el desempeño de la maquinaria. Se considera que el aire comprimido es un recurso en grado de importancia superior al agua y al combustible (Guerra, 2013). La aplicación del aire comprimido en la industria radica en su alta disponibilidad y eficiencia energética. Yang (2009) menciona que la eficiencia energética del aire comprimido oscila entre el 90 % y 95 %. Por estas razones monitorear a un compresor es una actividad esencial en el marco de evitar paradas no programadas en la producción a causa de un fallo que no ha sido controlado. Guerra (2013) menciona que los fallos en válvulas representan el 36 % del total

1. INTRODUCCIÓN

de fallas que pueden darse en un compresor, además menciona que el 50% del costo total de reparación en los compresores se debe a las válvulas (Guerra, 2013).

Es por aquello que surge la obligación como responsables de las industrias de buscar soluciones para detectar estos fallos a tiempo, es por eso que la finalidad de implementar estrategias que reduzcan costos debido a paradas es una forma de cuidar nuestros activos (Verma et al., 2016).

Para abordar este problema, se han desarrollado métodos para la creación de modelos capaces detectar el estado de los compresores. Zhang y Zhang (2022) utilizaron un nuevo marco de detección de fallos basado en datos discretos para detectar de forma inteligente fallos presentes en compresores recíprocos. El método propuesto fue validado en cuatro casos de fallos en un compresor recíproco. El resultado demostró la eficacia del método propuesto en la detección de condiciones anormales.

Por otra parte en (Pichler et al., 2016) se propuso un enfoque para la detección de fallos en válvulas de un compresor recíproco mediante la aplicación de máquinas de vectores de apoyo. Los resultados mostraron una precisión de detección muy alta, manteniendo las tasas de falsa alarma en un nivel muy bajo para diferentes condiciones de trabajo presentes en el compresor.

Guamán (2019) utilizó la metodología tradicional de aprendizaje automático para desarrollar un modelo basado en datos para la detección de fallos en un compresor recíproco de simple efecto, el cual consiste en extraer las características, seleccionarlas y clasificar patrones. Guamán (2019) enunció que las válvulas son elementos clave de los compresores y la detección de fallos resulta en muchos casos complicada de realizar.

En el procesamiento de señales, el análisis de componentes principales (“Principal Component Analysis - PCA”) es una técnica que permite la extracción de características buscando la reducción de la dimensionalidad de los datos de estudio (Jolliffe, 2002). Ahmed et al. (2012) utilizó el PCA para la detección de fallos y el diagnóstico de un compresor recíproco. El objetivo de este trabajo fue emplear PCA para la reducción de la dimensionalidad de los datos de vibración generados por el compresor y un control estadístico para detectar la presencia de un fallo en estos conjuntos de datos. En el campo de la detección de fallos, Uluyol et al. (2006) empleó PCA para la detección de fallos en un motor de una turbina de gas reduciendo el tamaño de los conjuntos de datos de

1. INTRODUCCIÓN

los sensores. Para eliminar los vectores de características irrelevantes, han utilizado una función de coste, que se basa en la distancia entre la salida del clasificador RNA y el conjunto de puntos de referencia.

Harrou et al. (2012) utilizó una técnica estadística multivariante como PCA en la detección de anomalías en las mediciones de ozono de la red de vigilancia en Normandía, Francia. Los datos tomados por los sensores han servido para la construcción de un modelo basado en PCA con datos sin fallos y otro con tres tipos de fallos. La detección se basó en un vector residual que, en una situación sin fallos, suele ser de pequeña magnitud pero puede aumentar en gran medida en presencia de un fallo. Entre otros resultados, Kresta et al. (1991) en una columna de destilación extractiva demostró que el uso de PCA en combinación con gráficos T^2 , gráficos Q y gráficos de contribución es una herramienta potente para la supervisión y el diagnóstico de fallos.

Misra et al. (2002) aplicó técnicas PCA a datos industriales de un sistema de reactor tipo tanque y comparó su rendimiento con el de un enfoque PCA multi - escala. Algunos investigadores han utilizado diferentes extensiones de PCA, como el PCA no lineal, multi - escala o ponderado exponencialmente (Lane et al., 2003). Garcia y Fuente (2011) compararon tres métodos de detección de fallos basado en PCA en una planta de agua potable. Los datos tomados en los sensores de nivel y la bomba centrífuga sirvieron para el modelado. El método PCA ponderado exponencialmente es el que mejores características de detección de múltiples fallos arrojó sobre PCA y PCA dinámico.

Loutas et al. (2020) utilizó las mediciones de temperatura de varios casos de fallo de válvulas de compresores recíprocos en servicio para desarrollar indicadores de salud basados en el análisis de componentes principales para la estimación probabilística de la vida útil restante. Usmani et al. (2018) en un tren de laminación en frío aplicó PCA en la FFT para diferenciar entre la condición de falla denominada “chatter” en la superficie de la banda y la condición saludable. Además, aplicó PCA a los parámetros estadísticos calculados a partir de los datos de vibración en bruto para detectar fallos.

Para mejorar el rendimiento de PCA, Zhu et al. (2021) propuso un enfoque robusto de PCA para la detección de fallos en sensores de centrales nucleares. Se utilizó un método estadístico basado en la distancia euclidiana para limpiar los valores atípicos en la fase de preprocesamiento de los datos de entrenamiento. Posteriormente, en la fase de detección de fallos, se adoptó el método de filtrado de media móvil para procesar la estadística

Q y reducir las falsas alarmas causadas por el ruido aleatorio en los datos de prueba. Finalmente se utilizó señales de simulación para verificar la eficacia del método propuesto.

Peng et al. (2020) evaluó PCA como técnica de aprendizaje automático no supervisado para detectar la causa de la rotura del eje en una bomba eléctrica sumergible (BES). Este método se aplicó con éxito en el bloque Penglai del campo petrolífero de Bohai, en China. El desarrollo del proyecto demostró que la aplicación del método PCA funciona bien en la supervisión del sistema de funcionamiento de la BES y predice la rotura inminente del eje de la BES con gran precisión. Otra aplicación de análisis de componentes principales fue presentada por Qi et al. (2018) quien utilizó PCA para procesar las señales de los compresores recíprocos en la industria petrolera. PCA fue una forma de eliminar el ruido de los datos utilizando ruido distribuido gaussiano, ampliamente utilizado en el procesamiento de señales e imágenes.

Como se puede evidenciar, PCA es un método probado que se ha utilizado ampliamente en la monitorización del estado de los sensores y la monitorización de procesos de diversas industrias. Existe varias aplicaciones de PCA; sin embargo, se necesita proponer nuevas metodologías enfocadas en la detección de fallos en compresores.

1.1.2. Importancia y Alcance

La importancia de desarrollar este trabajo radica en la utilización de señales en condición normal para entrenar al modelo de detección, en comparación con lo que se propone en otros trabajos de modelado de datos en los que se utiliza datos en condición normal y con falla para la detección de fallos (Villacís Marín, 2020).

Aunque se ha realizado una buena cantidad de trabajos para detectar fallos en compresores recíprocos empleando diversas técnicas de aprendizaje automático, se ha realizado muy poco trabajo empleando únicamente datos de condición normal. Así mismo un modelo de detección a partir de señales en condición de fallo resulta poco práctico debido a que se tendría que inducir fallos en los procesos para recopilar datos y construir el modelo. En la mayoría de los casos es muy sencillo obtener datos en condición normal, si el sistema de estudio se encuentra bien instrumentado.

PCA requiere un entrenamiento inicial, etapa en la cual se fija un modelo estadístico de detección, así como también se fijan los umbrales para los estadísticos. Ya que esta técnica implícitamente asume que las observaciones en un determinado instante son

1. INTRODUCCIÓN

estadísticamente independientes de otras observaciones en instantes anteriores o futuros, no considera eventuales cambios en la estructura de varianzas del proceso en el tiempo (Portnoy De la Ossa et al., 2014). Por lo tanto, puede ser aplicado en procesos ciclo-estacionarios presentes en el compresor reciprocante.

1.1.3. Delimitación

Con el desarrollo del presente trabajo se pretende proporcionar información eficaz, confiable y estructurada que sirva en el campo de la investigación con miras hacia industrias que deseen implementar un mantenimiento basado en la condición en compresores reciprocantes. Concretamente el estudio se realiza en los laboratorios del grupo de investigación y desarrollo en tecnologías industriales (GIDTEC) de la Universidad Politécnica Salesiana.

El laboratorio de vibraciones cuenta con un compresor reciprocante, simple efecto, doble etapa que permite emular diferentes fallos en elementos mecánicos. Los tipos de fallos que se pueden emular son en rodamientos en la pista externa, pista interna y elementos rodantes. También es posible emular fallos en válvulas como son el desgaste en el asiento válvula, corrosión en el plato de la válvula, fractura del plato de la válvula y la rotura del resorte.

Con los fallos planteados y la condición normal del compresor, se pretende evaluar y entrenar respectivamente un modelo basado en datos. La finalidad es aportar información sistematizada que sirva de soporte investigativo para la mejora de esta técnica aplicada a maquinaria dentro del monitoreo de la condición. El GIDTEC se encargará del estudio para la realización de trabajos futuros con miras a implementarlo en la industria donde se requiera y se necesite aplicar monitoreo de la condición sin someter a la maquinaria a inducirle fallos, debido a que este es el eje central del trabajo presentado.

1.2. Objetivos

El presente trabajo busca dar solución al problema planteado de detección de fallos en un compresor reciprocante mediante la ejecución de los siguientes objetivos.

1.2.1. Objetivo General

- Desarrollar un modelo basado en análisis de componentes principales para la detección de fallos en un compresor reciprocante de simple efecto, doble etapa solamente a

partir de señales en condición normal.

1.2.2. Objetivos Específicos

- Caracterizar las señales de vibración provenientes del compresor recíprocante simple efecto doble etapa bajo diferentes condiciones de funcionamiento.
- Diseñar una metodología para la creación de modelos basados en PCA para la detección de fallos en compresores recíprocantes mediante señales de vibración.
- Evaluar la metodología propuesta en el objetivo anterior mediante datos colectados del compresor funcionando bajo distintas condiciones de fallo en válvulas.
- Proponer un sistema de detección de fallos en línea para compresores recíprocantes.

2. MARCO TEÓRICO

El presente capítulo describe la teoría necesaria para manejar la metodología propuesta, se aborda temas enfocados en el mantenimiento, fallos presentes en el compresor y modelamiento basado en datos.

2.1. Mantenimiento basado en la condición

Se conoce desde antes que el mantenimiento ha tratado de enfocarse en monitorear la condición de los equipos rotatorio en este caso la tecnología recíproca con el único fin de garantizar una alta disponibilidad en las industrias (Tsang, 1995). Para la ejecución de estas actividades dentro del mantenimiento basado en la condición se utilizan técnicas como son el monitoreo de vibraciones para evaluar el estado de un equipo en base a datos tomados de él. Lo que se quiere es que mediante estos datos se pueda apreciar cambios en ellos y por ende definir un estado de la máquina que puede ser con fallo o condición normal (Mobley, 2002).

2.2. Monitoreo de la condición

Se conoce que dentro del mantenimiento de la condición existe el monitoreo de la condición el cual como se describió toma un conjunto de patrones a través de señales y obtiene información del estado de un equipo (Randall, 2011; Waarli, 2010). El estado del equipo muchas veces es medido mediante variables físicas presentes naturalmente en el equipo de análisis (Jardine et al., 2006).

2.2.1. Monitoreo de vibraciones

Se conoce que este tipo de señales de vibración ayudan a diagnosticar alrededor del 90 % de fallos en compresores (Devendiran y Manivannan, 2016; Potočnik y Govekar, 2017). Sin embargo, esta metodología de análisis no es tan eficaz dado que en la industria se cuenta con ruido de otras máquinas que puede ser confundido con la presencia de fallos (Sánchez Loja, 2017).

2.2.2. Emisiones acústicas

La emisión acústica es una técnica que forma parte del monitoreo de la condición. La forma en la que se realiza el monitoreo es mediante las ondas de sonido emitidas las cuales pueden ser causadas por fallas o discontinuidades (Goel et al., 2014). En las máquinas eléctricas, las fuentes de emisiones acústicas se pueden apreciar en impactos, fatiga cíclica, fricción, turbulencia, pérdida de material, cavitación, fugas, etc (Nandi y Ahmed, 2019).

Las emisiones acústicas a menudo se propagan en la superficie del material como ondas de Rayleigh; y el desplazamiento de estas ondas se mide mediante micrófonos, que suelen ser piezoeléctricos. En comparación con el monitoreo de vibraciones, el monitoreo de emisiones acústicas puede proporcionar una mayor relación señal-ruido en un entorno de alto ruido (Zhou et al., 2007). Sin embargo, tiene dos inconvenientes principales: (i) experimenta altos costos del sistema y (ii) requiere experiencia especializada para adquirir emisiones acústicas (Nandi y Ahmed, 2019).

2.2.3. Monitoreo de corriente del motor

El monitoreo de corriente del motor también se puede usar para el monitoreo basado en la condición. Para este caso en particular no se necesitan sensores adicionales para implementar el monitoreo de corriente para máquinas eléctricas. Aquí, las medidas eléctricas básicas asociadas con las plantas electromecánicas se miden fácilmente aprovechando los transformadores de voltaje y corriente existentes que a menudo se instalan como parte del sistema de protección (Zhou et al., 2007).

2.2.4. Termografía

La termografía forma parte de las técnicas del monitoreo de la condición, no es intrusiva y permite una alta gama de análisis. La técnica trata de que mediante imágenes podamos visibilizar la presencia de fallos en las máquinas, en muchas de las ocasiones una temperatura muy elevada es la presencia de un fallo (Bagavathiappan et al., 2013).

2.3. Compresores

Los compresores son máquinas mecánicas que aumentan la presión del aire y permiten en muchas de las veces su almacenamiento. De los compresores nacen redes de aire comprimido que llevan este tipo de energía a otras partes para su utilización (Fernández, 2000).

2.3.1. Tipos de compresores

En la actualidad existen un sin fin de tipos de compresores, cada uno enfocado en una rama de la humanidad, en el presente caso usamos un compresor industrial de desplazamiento positivo. En la Figura 1 se muestra la principal clasificación por su principio de funcionamiento.

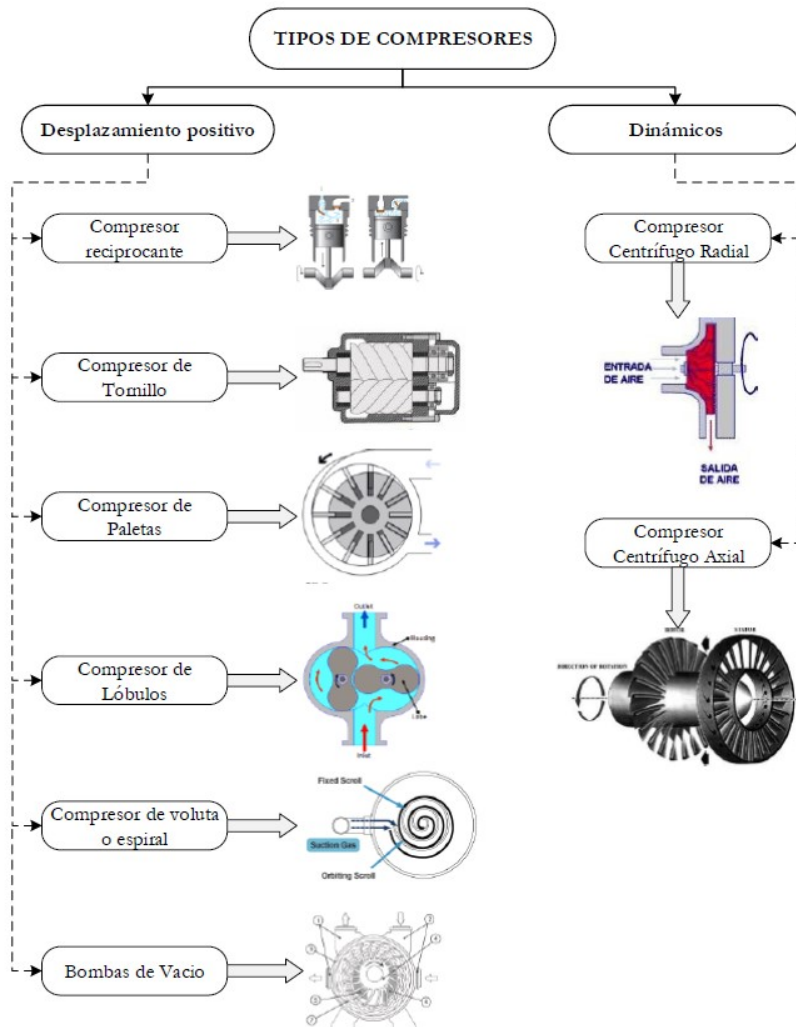


Figura 1: Clasificación de los tipos de compresores según su principio de funcionamiento.
Fuente: (Cajas Muñoz y Torres Díaz, 2018)

2.3.2. Fallos comunes en compresores recíprocantes

Los compresores son el corazón de las fábricas esto se debe a que son la principal fuente de energía (Ahmad y Kamaruddin, 2012). Es por eso que en la literatura se reporta que la gran cantidad de fallos se presenta en rodamiento y válvulas (Jiang, Zhang, Jin, y Ma, 2013).

2.4. Análisis de componentes principales

El control estadístico multivariado de procesos es una estrategia que permite monitorear y controlar los procesos productivos en la industria. Una técnica de modelado estadístico multivariante es el análisis de componentes principales denominada en inglés, Principal Component Analysis - PCA (Mina y Verde, 2004). Esta técnica para la monitorización de procesos ha sido estudiada tanto en el plano industrial como en el académico. Su estudio se debe principalmente a tres factores:

- Puede representar los datos observados en una menor dimensión que mejor generalice la independencia de los datos.
- La estructura de PCA es útil para identificar las variables responsables de los fallos.
- Permite separar el espacio de observación en un subespacio que capture la tendencia del proceso y otro que contenga el ruido (García y Fuente, 2011).

El objetivo principal de PCA es la reducción de la dimensionalidad o la compresión de datos para lograr su óptimo análisis de datos. PCA forma un nuevo conjunto más pequeño de variables con una mínima pérdida de información en comparación con los datos originales. Basado en esta característica, PCA puede utilizarse para la clasificación de variables y, por lo tanto, la identificación temprana de anomalías en la estructura de datos, en otras palabras, la detección de fallos (Jackson y Mudholkar, 1979).

PCA puede ser modelado a través de la matriz de covarianza o la matriz de correlación, para lo cual se transforma las variables correlacionadas originales, en un nuevo conjunto de variables no correlacionadas. Si consideramos al conjunto de datos que describen a la máquina que se investiga como una matriz $X \in \mathfrak{R}^{n \times m}$ que representan las n muestras tomadas de m variables del proceso como se describe en la ecuación (1).

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

El procedimiento para llegar a obtener las componentes principales es el que se describe a

continuación:

1. Estandarizar los datos con media cero y varianza unitaria mediante la ecuación (2), dado que las m -variables pueden tener rangos muy diferentes dando consigo \bar{X} .

$$\bar{X} = \frac{(X - \mu)}{\sigma} \quad (2)$$

2. Obtener la matriz de covarianza Σ de \bar{X} como se muestra en la ecuación (3).

$$\Sigma = \frac{\bar{X}^T \cdot \bar{X}}{m} \quad (3)$$

3. A partir de la matriz de covarianza de \bar{X} realizar la descomposición de valores Λ y vectores propios P mediante la ecuación (4).

$$\Sigma \cdot P = \lambda \cdot P \quad (4)$$

4. Para obtener la (eigendecomposition) propuesta en la ecuación (4) es necesario calcular la solución al polinomio característico mostrado en la ecuación (5). El cual nos permite encontrar los valores propios y vectores propios asociados, considere que I corresponde a la matriz identidad.

$$P(\lambda) = \det(\Sigma - \lambda I) \quad (5)$$

Los m -valores propios (λ) se encuentran ordenados decrecientemente dando consigo la matriz diagonal de valores propios (6). Adicionalmente se encuentra constituida por los vectores propios (P) mutuamente ortogonales y asociados a los valores propios. Esta matriz de vectores propios puede ser expresada mediante la ecuación (7).

$$\Lambda = \begin{bmatrix} \Lambda_l & 0 \\ 0 & \Lambda_{m-l} \end{bmatrix} \quad (6)$$

$$P = \begin{bmatrix} P_l & P_{m-l} \end{bmatrix} \quad (7)$$

Este conjunto de valores propios asociados pueden también ser determinados mediante

la ecuación (8) y la matriz identidad mediante la ecuación (9).

$$P^T \Sigma P = \lambda \quad (8)$$

$$P^T P = I \quad (9)$$

En esta etapa, se puede aplicar la transformación del eje principal para transformar los datos en valores independientes, los cuales se describen en la ecuación (10).

$$Y = P^T \bar{X} \quad (10)$$

La matriz de vectores propios P se denomina matriz de proyección y las variables transformadas Y se denominan **componentes principales**.

- A partir de P y Y se puede volver al espacio de partida mediante la ecuación (11).

$$\bar{X} = \sum_{i=1}^m Y_i P_i^T \quad (11)$$

Donde Y_i es el valor i -ésimo del vector de scores y P_i la columna i -ésima de la matriz P .

- Cuando se escoge el total de componentes principales la variable \hat{X} es igual a la variable \bar{X} que provoca que el error residual sea cero. Por otra parte si utilizamos una menor cantidad de componentes va a aparecer un error residual. La diferencia entre \bar{X} y \hat{X} es la matriz de residuos mostrada en la ecuación (12).

$$E = \bar{X} - \hat{X} \quad (12)$$

- Finalmente para regresar a la variable \bar{X} se lo puede hacer mediante la expresión mostrada en la ecuación (13).

$$\bar{X} = \sum_{i=1}^m Y_i P_i^T + E \quad (13)$$

Lo que se espera con PCA es que las variables originales estén lo suficientemente bien correlacionadas como para que sólo un número relativamente pequeño de las nuevas

variables represente la mayor parte de la varianza.

2.5. Detección de fallos mediante pruebas de hipótesis

La detección de fallos puede plantearse mediante la comprobación de una hipótesis binaria donde se tiene una hipótesis nula \mathcal{H}_0 que indica la ausencia de un fallo y una hipótesis alternativa \mathcal{H}_1 que indica la presencia de un fallo. Si suponemos que Y es una variable aleatoria con una distribución P_θ que pertenece a una familia paramétrica de distribuciones $P = \{P_\theta\}$ podremos realizar un contraste paramétrico sobre si un valor de un parámetro se distribuye de acuerdo a la hipótesis enunciada (Lehmann y Lehmann, 1986).

Para este caso consideraremos una hipótesis compuesta que supone un conjunto de parámetros $\theta \in \Theta$ que indican la posible existencia de fallos con diferentes magnitudes en el espacio paramétrico Θ . Una forma de resolver el problema de las pruebas de hipótesis compuestas es utilizando la relación de verosimilitud generalizada (GLRT, por sus siglas en inglés) (Ferguson, 2014).

GLRT es un importante método estadístico que puede utilizarse para resolver problemas de comprobación de hipótesis compuestas maximizando la función de razón de verosimilitud sobre todos los posibles fallos. GLRT proporciona un marco de detección de fallos que tiene la capacidad de manejar la presencia de ruido e incertidumbres en los datos mediante la utilización de pruebas de hipótesis para decidir entre dos hipótesis, la ausencia de fallos y la presencia de fallos (Majdi et al., 2020).

Si se considera al problema de detección de fallos, en el que un vector $E \in \mathbb{N}$ sigue una de las dos distribuciones gaussianas, $\mathcal{N}(\theta = 0, \sigma^2 I_N)$ o $\mathcal{N}(\theta \neq 0, \sigma^2 I_N)$, donde θ es la desviación causada en la media debido al fallo, y $\sigma^2 > 0$ es la varianza, que se supone tiene un valor conocido. Ahora el problema de la prueba de hipótesis busca decidir entre dos hipótesis, la hipótesis nula y la hipótesis alternativa como se muestra en la ecuación (14).

$$\begin{cases} \mathcal{H}_0 = \{E \sim \mathcal{N}(0, \sigma^2 I_N)\} & \text{(hipótesis nula)} \\ \mathcal{H}_1 = \{E \sim \mathcal{N}(\theta, \sigma^2 I_N)\} & \text{(hipótesis alternativa)} \end{cases} \quad (14)$$

Sea $f_\theta(E) = \frac{1}{(2\pi)^{\frac{N}{2}} \sigma^N} \exp\left\{-\frac{1}{2\sigma^2} \|E - \theta\|_2^2\right\}$ la función de densidad de probabilidad de Y . GLRT estima el parámetro desconocido θ utilizando la estimación de máxima verosimilitud

2. MARCO TEÓRICO

mediante la maximización de la relación de verosimilitud generalizada $G(E)$ con la siguiente ecuación (15):

$$G(E) = 2 \cdot \log \cdot \frac{\sup_{\theta \in \mathbb{R}^N} f_{\theta}(E)}{f_{\theta=0}(E)} \quad (15)$$

$$G(E) = 2 \cdot \log \cdot \left\{ \sup_{\theta} \exp \left\{ -\frac{\|E-\theta\|_2^2}{2 \cdot \sigma^2} \right\} / \exp \left\{ \frac{\|E\|_2^2}{2 \cdot \sigma^2} \right\} \right\}$$

$$G(E) = \frac{1}{\sigma^2} \cdot \left\{ \min_{\theta} \|E - \theta\|_2^2 + \|E\|_2^2 \right\}$$

$$G(E) = \frac{1}{\sigma^2} \cdot \left\{ \|E - \hat{\theta}\|_2^2 + \|E\|_2^2 \right\}$$

$$G(E) = \frac{1}{\sigma^2} \cdot \left\{ \|E\|_2^2 \right\}$$

$$G(E) = \sum_{i=1}^m \left[\frac{E_i}{\sigma_i} \right]^2$$

- Donde, $\theta = \arg \min_{\theta} \|E - \theta\|_2^2 = E$ es la estimación de máxima verosimilitud de θ .
- La norma euclidiana es representada mediante $\|\cdot\|_2$.

Es importante señalar que en esta derivación maximizamos la función de verosimilitud, maximizando su logaritmo natural debido a que la función logarítmica es monótona. Así, la GLRT decide entre la hipótesis \mathcal{H}_0 y \mathcal{H}_1 como se describe en la ecuación (16):

$$\delta(E) = \begin{cases} H_0 & \text{Si, } G(E) < G_{\alpha} \\ H_1 & \text{otro caso} \end{cases} \quad (16)$$

Esto quiere decir que conocer la distribución de la función de decisión $G(E)$, bajo la hipótesis nula \mathcal{H}_0 permite diseñar una prueba estadística con una tasa de falsa alarma deseada α , donde el umbral G_{α} se selecciona para satisfacer la siguiente probabilidad de falsa alarma descrita en la ecuación (17).

$$P_0(\Lambda(E) \geq G_{\alpha}) = \alpha \quad (17)$$

Donde $P_0(A)$ es la probabilidad de un evento A cuando E se distribuye según la hipótesis nula \mathcal{H}_0 , como se supone que E se distribuye normalmente, el estadístico $G(E)$ sigue una distribución chi-cuadrado χ^2 mostrada mediante la resolución de la ecuación (15). Está distribución chi-cuadrado es central bajo \mathcal{H}_0 y no central bajo \mathcal{H}_1 con un parámetro de no centralidad igual a $k_{\theta} = \frac{1}{\sigma^2} \|\theta\|_2^2$.

2. MARCO TEÓRICO

Varias técnicas de detección de fallos requieren la disponibilidad de modelos precisos del proceso. Sin embargo, estos modelos no siempre están disponibles debido a la complejidad y la alta dimensionalidad de los sistemas monitorizados. Para hacer frente a este problema, se puede utilizar PCA para representar una matriz de datos del proceso como la suma de dos partes ortogonales (una matriz de datos aproximada y una matriz de datos residuales), como se muestra en la ecuación (13).

Esta representación de los datos basada en PCA puede proporcionar un modelo que puede ser utilizado en la detección de fallos basada en el modelo. El problema de la detección de fallos basada en el modelo suele constar de dos pasos principales: la generación de residuos basada en el uso de un modelo de proceso y, a continuación, la evaluación de estos residuos mediante una prueba estadística.

El objetivo de desarrollar el método de detección de fallos basado en PCA y la prueba de hipótesis GLRT, es disponer de una técnica de detección de fallos insensible al ruido de las mediciones, pero sensible a la presencia de fallos, lo que puede lograrse integrando PCA y la prueba de hipótesis GLRT. Dado que el modelo PCA expresa una matriz de datos como la suma de una matriz aproximada y una matriz residual, los residuos E véase en la ecuación (12) obtenidos mediante PCA pueden evaluarse utilizando la GLRT para detectar fallos.

Para ello, primero se estima un modelo PCA utilizando un conjunto de datos de entrenamiento sin fallos obtenidos en condiciones normales de funcionamiento y, a continuación, se utiliza el modelo PCA para generar los residuos, que se evalúan utilizando GLRT como se muestra en la Figura 2.




Figura 2: Diagrama del método de detección de fallos basado GLRT - PCA. **Fuente:** Autor.

2. MARCO TEÓRICO

Así pues, esta técnica de detección de fallos GLRT basada en PCA trata de detectar la presencia de un vector de fallos aditivo, que no se explica por el modelo PCA. La detección de este vector de fallos aditivo θ puede formularse como un problema de comprobación de hipótesis, considerando dos posibles hipótesis: una hipótesis nula \mathcal{H}_0 (en la que un vector medido x no tiene fallos) y una hipótesis alternativa \mathcal{H}_1 (en la que x contiene un fallo y, por tanto, x ya no se explica por el modelo PCA estimado utilizando los datos sin fallos) (Majdi et al., 2020).

3. METODOLOGÍA PROPUESTA

El presente capítulo describe el procedimiento para la construcción del modelo basado en datos para la detección de fallos en el compresor. Se explica como se realiza la adquisición de señales de vibración, para posteriormente mostrar cómo los datos fueron generados desde la experimentación, además se explica al lector como se realiza la construcción del modelo de detección y finalmente se explica como se diseño el sistema de detección de fallos empleado.

La construcción de modelos basados en datos para la detección de fallos en muchos casos es difícil de realizar ya que se necesita de señales en condición normal y con fallo para su respectivo entrenamiento. Para el presente trabajo se utiliza únicamente señales en condición normal para la construcción del modelo basado en PCA. En la Figura 3 se puede observar el esquema de la metodología propuesta para dar solución al problema planteado.

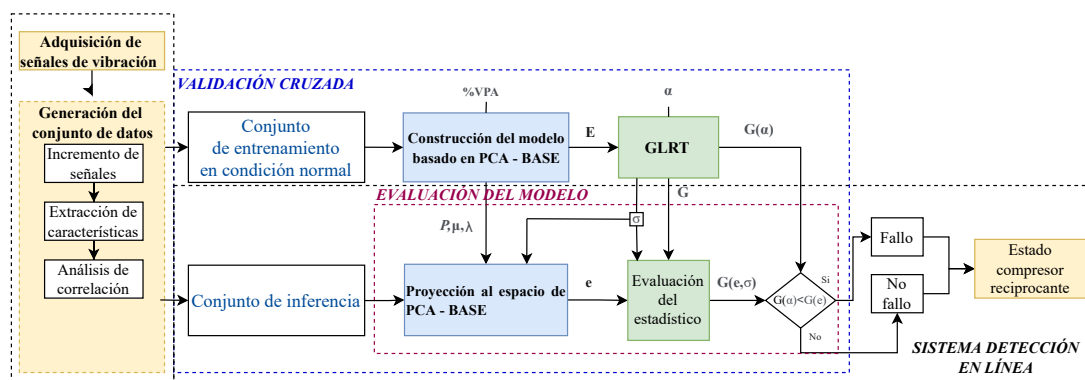


Figura 3: Metodología empleada para la detección de fallos. **Fuente:** Autor.

La metodología se baso en utilizar señales de vibración en condición normal para el entrenamiento. Estas señales fueron analizadas, modificadas y sintetizadas. Posteriormente con estos datos procesados se entrenó un modelo basado en PCA. La evaluación del modelo generado se realizo mediante los datos colectados del funcionamiento anormal de la máquina. Finalmente, el modelo generado se puso a prueba en un sistema en línea de detección de fallos. Los pasos principales empleados para la metodología propuesta se describen a continuación:

1. Adquisición de señales.
2. Generación del conjunto de datos.

3. METODOLOGÍA PROPUESTA

3. Construcción del modelo de detección.
4. Sistema de detección de fallos en línea.

3.1. Adquisición de señales

Para el estudio de la presente investigación se utilizó señales de vibración provenientes de un compresor recíprocante. Para la construcción del modelo se utilizó los datos tomados en condición normal y para la evaluación del modelo se empleó los datos colectados con fallos.

3.1.1. Banco de pruebas para un compresor recíprocante simple efecto doble etapa

La adquisición de señales útiles para el desarrollo de la metodología se utilizó el compresor que emula fallos disponible en las instalaciones de la Universidad Politécnica Salesiana. El banco está estructurado por una unidad de mando, una de adquisición de datos y una maquinaria recíprocante como se presenta en la Figura 4.




Figura 4: Banco de pruebas experimentales para compresor. **Fuente:** Adaptado de (Guamán, 2019).

3. METODOLOGÍA PROPUESTA

3.1.2. Sistema de adquisición de señales de vibración

En la Figura 5 se muestra el sistema de adquisición de datos. Las señales de vibración son adquiridas por un acelerómetro piezoeléctrico (b) modelo IPC 603C01 que se emplazó en el cabezote del compresor (a) modelo EBG 250. La señal del acelerómetro se adquirió a 50 kS/s por la tarjeta (c) NI cDAQ-9234. A su vez, la tarjeta NI 9234 se conecta en el chasis (d) NI cDAQ-9188 que envía datos vía Ethernet al computador portátil (e) ASUS ROG GL752VWDH74 que dispone de LabVIEW y Matlab para la adquisición de las señales.




Figura 5: Esquema del sistema de adquisición de las señales de vibración. **Fuente:** Adaptado de (Guamán, 2019).

Para la toma de datos se ha empleado un acelerómetro ICP - 603C01 con una sensibilidad de 100 mV/g ($\pm 10\%$). Un rango de medición de ± 50 g, un rango de frecuencia de 0.5 a 10000 Hz (± 5 dB), una frecuencia de resonancia de 25 kHz y una resolución de ancho de banda de 350 μ g.

Para la adquisición se ha empleado una tarjeta NI cDAQ-9234 con las siguientes características: máxima velocidad de muestreo de 51.2 kS/s por canal, un rango de voltaje máximo de ± 5 V DC, cuenta con cuatro canales, una resolución de 24 bits; rango dinámico de 102 dB; filtros anti-aliasing, el acondicionamiento de señales mediante IEPE, y el acoplamiento de AC/DC es seleccionable por software.

Finalmente, el chasis NI cDAQ-9188 cuenta con una capacidad de hasta 256 canales, con ocho ranuras, cuenta con disparo integrado, una potencia de 15W y un rango de entrada

3. METODOLOGÍA PROPUESTA

entre 9 - 30 V DC.

3.1.3. Fallos implantados en válvulas

Para la descripción de la posición de los fallos en válvulas se ha empleado la codificación que se describe en la Figura 6, mientras que una descripción de la vista superior del cabezote del compresor se describen en la Figura 7. Para el primer término de la nomenclatura “#S” corresponden a la posición de acuerdo con la etapa: (1S) para primera etapa y (2S) segunda etapa; el segundo término “#V”, corresponde a la función de la válvula: (IV) para válvula de admisión y (DV) para válvula de descarga; el tercer término que va luego del término “#V” solo se coloca cuando existen dos válvulas que cumplen la misma función y puede ser “a” o “b”; el último término “#” corresponde al tipo de fallo generado y “_1” desgaste en el asiento de la válvula, “_2” corrosión del plato, “_3” fractura del plato y “_4” rotura del resorte.




Figura 6: Codificación para la identificación de válvulas. **Fuente:** Adaptado de (Guamán, 2019).


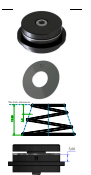






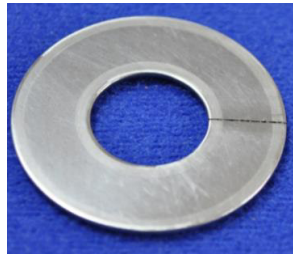
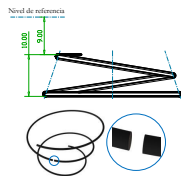



Figura 7: Vista superior del cabezote del compresor. **Fuente:** Adaptado de (Guamán, 2019).

3. METODOLOGÍA PROPUESTA

Para el experimento propuesto se utilizaron cuatro diferentes tipos de fallos; desgaste del asiento de la válvula, corrosión de la placa de la válvula, grieta de la placa de la válvula y rotura del resorte. Se simularon 25 condiciones de trabajo en el compresor como se indica en la Tabla 2, cada condición de trabajo se denota con la letra P. Se simuló la condición normal denominado P1, y 24 condiciones con diferentes fallos en diferentes válvulas (de P2 a P25). Una explicación de los tipos de fallos emulados artificialmente en las válvulas se describen en la Tabla 2.

Tabla 1: Detalles de la construcción de los fallos y su localización. **Fuente:** Adaptado de (Guamán, 2019).

Referencia	Código	Tipo de fallo	Esquema del fallo	Fotografía del fallo
(Guamán, 2019)	N	No Fallo Condición Normal.		
(Guamán, 2019)	1S_DV_1 2S_IV_1 2S_DV_1 1S_Vb_1.	Desgaste en el asiento de la válvula, profundidad de desbaste: 1.44 mm.		
(Guamán, 2019)	1S_DV_2 2S_IV_2 2S_DV_2 1S_IVb_2	Corrosión en el plato de la válvula, diámetro: 2.50 mm.		
(Guamán, 2019)	1S_DV_3 2S_IV_3 2S_DV_3 1S_IVb_3	Fractura del plato válvula, diámetro del hilo: 1.6mm, longitud: total.		
(Guamán, 2019)	1S_DV_4 2S_IV_4 2S_DV_4 1S_IVb_4	Rotura del resorte, longitud para el corte: 9,00 mm.		

3. METODOLOGÍA PROPUESTA

Tabla 2: Localización de los fallos en las válvulas del compresor. **Fuente:** Adaptado de (Guamán, 2019).

Condición	1S_IVa	1S_IVb	1S_DV	2S_IV	2S_DV
P1	N	N	N	N	N
P2	N	N	N	N	2S_DV_1
P3	N	N	N	N	2S_DV_2
P4	N	N	N	N	2S_DV_3
P5	N	N	N	N	2S_DV_4
P6	N	N	N	2S_IV_1	N
P7	N	N	N	2S_IV_2	N
P8	N	N	N	2S_IV_3	N
P9	N	N	N	2S_IV_4	N
P10	N	N	1S_DV_1	N	N
P11	N	N	1S_DV_2	N	N
P12	N	N	1S_DV_3	N	N
P13	N	N	1S_DV_4	N	N
P14	N	1S_IVb_1	N	N	N
P15	N	1S_IVb_2	N	N	N
P16	N	1S_IVb_3	N	N	N
P17	N	1S_IVb_4	N	N	N
P18	N	N	N	2S_IV_1	2S_DV_1
P19	N	N	N	2S_IV_2	2S_DV_2
P20	N	N	N	2S_IV_3	2S_DV_3
P21	N	N	N	2S_IV_4	2S_DV_4
P22	N	1S_IVb_1	N	N	2S_DV_1
P23	N	1S_IVb_2	N	N	2S_DV_2
P24	N	1S_IVb_3	N	N	2S_DV_3
P25	N	1S_IVb_4	N	N	2S_DV_4

3.2. Generación del conjunto de datos

Terminada la etapa de adquisición de señales de vibración se seleccionó únicamente los datos del acelerómetro 1 que se encuentra más cercano a las válvulas. La posición del presente acelerómetro que se describe en la Figura 8 ha sido seleccionado acuerdo a la norma internacional ISO 20816 - 8 : 2018 y a los trabajos reportados por Guamán (2019) y Cajas Muñoz y Torres Díaz (2018) para el mismo caso de estudio.




Figura 8: Ubicación del acelerómetro en el compresor. **Fuente:** Adaptado de (Guamán, 2019).

3.2.1. Incremento de señales

Para la construcción de modelos de detección de fallos es necesario contar con una muestra representativa de los datos. Sin embargo, no siempre se pueden obtener, debido a que generan altos costos y tiempo excesivo en su adquisición. Una herramienta que solventa desde el punto de vista económico y técnico la planteo Guaman Buestan et al. (2018), y se describe a continuación.

Para aplicar este proceso se tomó a todo el conjunto de datos compuesto por señales de 500000 muestras y se las dividió en subseñales más pequeñas para lo cual se utilizó una ventana de 50000 muestras y un desplazamiento de 8600 muestras como se puede apreciar en la Figura 9 . La selección de la ventana de 50000 muestras garantiza al menos 10 ciclos completos de compresión. Considerando que el tiempo de adquisición de cada señal es de 10s y que el proceso de compresión se efectúa en 0.158s reportado en el trabajo de Guamán (2019).

Por otra parte el desplazamiento de 8600 muestras fue seleccionado en función de la cantidad de subseñales que se quería obtener al final del proceso de división de las señales.

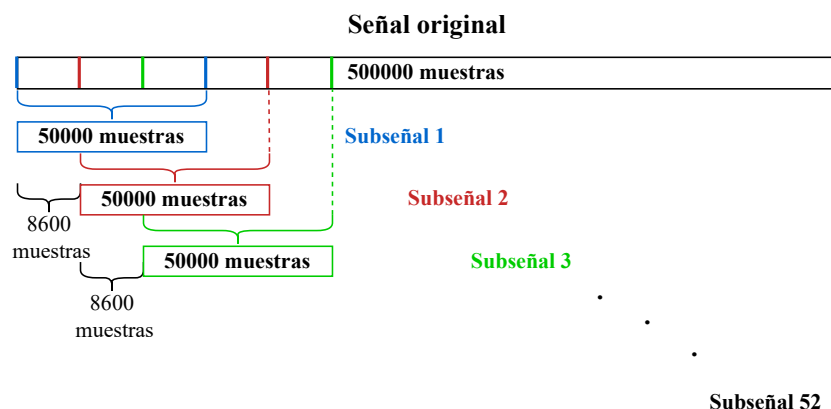


Figura 9: División de una señal. **Fuente:** Autor.

3.2.2. Extracción de características

Para la fase de extracción de características estadísticas se utilizó las que recomienda Sánchez Loja (2017) para la creación de modelos de detección de fallos. Las características que se extrajeron en el dominio del tiempo se describen en la Tabla 4. Dichas características necesitan tener una alta correlación para que el modelado basado en PCA tenga mejores resultados en su construcción (Peña, 2002).

Para tal situación se debe utilizar la matriz de correlación mostrada en la Tabla 3. La tabla de doble entrada nos indica la relación que existe entre las parejas de características. Es denotada por un coeficiente que va desde (-1 a 1). Toma el valor de 0 cuando existe una nula correlación y tiende a (-1 o 1) cuando existe una alta correlación.

Tabla 3: Ejemplo de matriz de correlación. **Fuente:** Autor.

Característica	A	B	C
A	1	0.3	0.75
B	0.3	1	0.95
C	0.75	0.75	1

3. METODOLOGÍA PROPUESTA

Tabla 4: Características en el dominio del tiempo. **Fuente:** Adaptado de (Villacís Marín, 2020).

Nombre de la Característica	Fórmula
Media	$T_1 = \frac{1}{n} \cdot \sum_{i=1}^n x_i$
Varianza	$T_2 = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - T_1)^2$
Desviación Estándar	$T_3 = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - T_1)^2}$
Media Cuadrática	$T_4 = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i)^2}$
Valor Máximo	$T_5 = \text{máx}(x_i)$
Curtosis	$T_6 = \frac{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - T_1)^4}{\left[\frac{1}{n} \cdot \sum_{i=1}^n (x_i - T_1)^2\right]^2}$
Asimetría	$T_7 = \frac{n \sum_{i=1}^n (x_i - T_1)^3}{T_3^3}$
Factor de Cresta	$T_8 = \frac{T_5}{T_4}$
Factor de Forma	$T_9 = \frac{T_4^4}{\frac{1}{N} \sum_{i=1}^n x_i }$
Factor de Impulso	$T_{10} = \frac{\text{máx}(x_i)}{\frac{1}{n} \cdot \sum_{i=1}^n x_i }$
Factor de Holgura	$T_{11} = \frac{T_5^5}{\frac{1}{N} \sum_{i=1}^N (x_i)^2}$
Log. entropía energética (LEE)	$T_{12} = \sum_{i=1}^n \log(x_i^2)$ donde $\log(0) = 0$
Entropía de Shannon	$T_{13} = - \sum_{i=1}^N x_i^2 * \log(x_i^2)$
Entropía de Sure	$T_{14} = n - \#\{i \text{ tal que } x_i \leq p\}$ $+ \sum_i \min(x_i^2, p^2);$ $p \text{ es igual a } 0,2$
Umbral de entropía	$T_{15} = \text{Umbral} \begin{cases} 1, & \text{Si } x_i > p, y \\ 0, & \text{cualquier otro caso} \end{cases}$ $p \text{ es igual a } 0,2$
CPT1	$T_{16} = \frac{\sum_{i=1}^n \log(x_i +1)}{n \log(T_3+1)}$
CPT2	$T_{17} = \frac{\sum_{i=1}^n \exp(x_i)}{n * \exp(T_3)}$
CPT3	$T_{18} = \frac{\sum_{i=1}^n \sqrt{ x_i }}{n * T_2}$
Ponderación SSR absoluta	$T_{19} = \frac{1}{n} (\sum_{i=1}^n \sqrt{ x_i })^2$
Detector logarítmico absoluta	$T_{20} = e^{\frac{1}{N} \sum_{i=1}^N \log x_i }$
Integral de la señal	$T_{21} = \sum_{i=1}^N x_i $
Quinto momento estático	$T_{22} = \sum (x_i - T_1)^5$
Sexto momento estático	$T_{23} = \sum (x_i - T_1)^6$
Valor Mínimo	$T_{24} = \text{mín}(x_i)$

3.2.3. Validación cruzada

En la fase de entrenamiento e inferencia es necesario verificar que los resultados que se obtienen son independientes del grupo de datos con los que se está probando el modelo. Para lo cual se empleó la técnica de validación cruzada, específicamente el método fue la validación cruzada dejando uno fuera. Esta técnica implica que en cada iteración se aislé una cantidad de datos del resto. Este método se repite la cantidad de veces que se requiera, una explicación visual se muestra en la Figura 10.

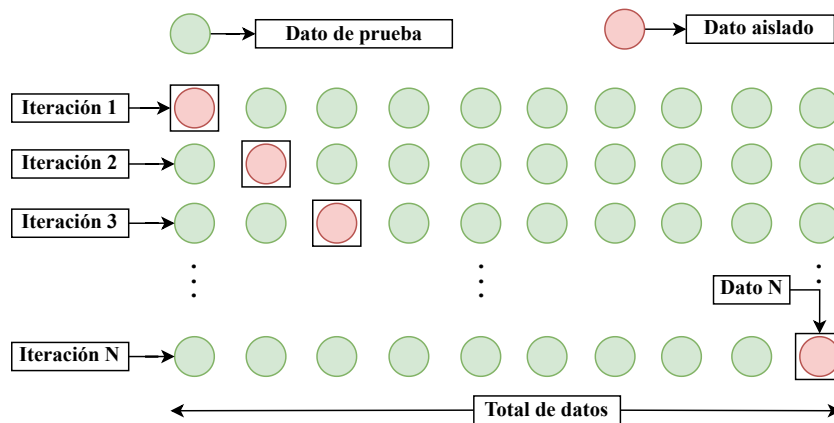


Figura 10: Validación cruzada dejando uno fuera. **Fuente:** Adaptado de .

3.3. Construcción del modelo de detección

Acabada la etapa de preprocesamiento de datos, la evaluación del estado del compresor se realiza con el modelado basado en datos propuesto. Para la construcción del modelo se emplearon los datos en condición normal (P1) para su entrenamiento; mientras que para evaluar el modelo de detección se emplearon los datos de las diferentes condiciones de fallo (P2 - P25). Para la etapa de entrenamiento se aplicó la secuencia de pasos mostradas en el Algoritmo 1, mientras que para la etapa de inferencia se utilizó el Algoritmo 2.

Los hiperparámetros de un modelo son los valores de las configuraciones utilizadas durante el proceso de entrenamiento. El modelo de detección basado en PCA utilizó los siguientes hiperparámetros:

- Varianza porcentual acumulada
- Probabilidad de falsa alarma fija α .

La técnica empleada para el modelado es la estimación de el número de componentes

3. METODOLOGÍA PROPUESTA

mediante la varianza porcentual acumulada (VPA). Esta técnica consiste en elegir el menor número de componentes que capturen un determinado porcentaje de varianza (Majdi et al., 2020). La precisión del modelo de detección depende de una correcta estimación del número de componentes principales. Si se infravalora el número de componentes, se corre el riesgo de dejar de lado características importantes presente en los datos. Si, por el contrario, se sobrevalora el número de componentes, se puede llegar a retener más ruido, lo que ocultaría información importante en los datos. Por lo cual, es esencial hacer una estimación precisa del número de componentes retenidos. Mediante la Figura 11 se puede apreciar como cada componente principal tiene un valor de varianza, pero cuando las varianzas de los componentes se suman de forma secuencial tenemos la VPA.

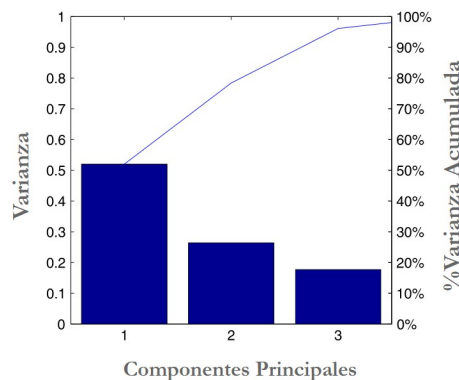


Figura 11: Varianza capturada por cada componente. **Fuente:** Autor.

Por otra parte, la probabilidad de falsa alarma fija α está asociada al umbral de detección. En la evaluación del modelo basado en datos, este umbral permite saber cuando existe una falla y puede ser analizada mediante un problema de prueba de hipótesis binaria donde el objetivo en la detección de fallos es tomar una decisión de Si/No sobre la presencia o ausencia de un fallo (Majdi et al., 2020).

3. METODOLOGÍA PROPUESTA

Algoritmo 1 Detección de fallos GLRT basado en PCA, entrenamiento.

Entrada: datos sin fallos $X \in \mathbb{R}^{n \times m}$, probabilidad de falsa alarma fija α , %VPA.

Salida: matriz de valores propios λ , matriz de vectores propios P , media μ de E , desviación estándar σ_1 de E y $G(\alpha)$.

- 1: Estandarizar datos mediante la ecuación (2) dando consigo \bar{X} .
 - 2: Obtener la eigendecomposition mediante las ecuaciones (3), (4), (5) para obtener los valores propios (λ) mostrados en la ecuación (??) y vectores propios (P) mostrados en la ecuación (7).
 - 3: Determinar el nuevo espacio de componentes principales mediante la ecuación (10) dando consigo Y .
 - 4: Seleccionar cantidad de componentes principales a usar en base a %CPV.
 - 5: Reconstruir un nuevo espacio \hat{X} a partir de la cantidad de componentes seleccionadas anteriormente y aplicando la ecuación (11).
 - 6: Obtener la matriz de residuos E mediante la ecuación (12).
 - 7: Determinar la media de E mediante $\mu = \frac{1}{n} \sum_{i=1}^n E_i$
 - 8: Calcular la desviación estándar σ_1 de E mediante $\sigma_1 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n |E_i - \mu|^2}$
 - 9: Estimar $G(\alpha)$ empleando el hiperparámetro probabilidad de falsa alarma fija α mediante la ecuación (15).
-

Algoritmo 2 Detección de fallos GLRT basado en PCA, inferencia.

Entrada: datos con fallos $X_T \in \mathbb{R}^{n \times m}$, matriz de valores propios λ , matriz de vectores propios P , media μ de E , desviación estándar σ_1 de E y $G(\alpha)$.

Salida: estado de la máquina.

- 1: Estandarizar datos mediante la ecuación (2) dando consigo \bar{X}_T considere que el valor de la media μ y desviación estándar σ se toman de la etapa de entrenamiento.
 - 2: Llevar los nuevos datos al espacio anterior de componentes principales (entrenamiento) mediante la ecuación (10) y utilizando la matriz de vectores propios P (entrenamiento), dando consigo Y_2 .
 - 3: Reconstruir un nuevo espacio \hat{X}_{T2} a partir de la matriz de componentes principales Y_2 y aplicando la ecuación (11), considere que para esta etapa se necesita utilizar la matriz de vectores propios P (entrenamiento).
 - 4: Estimar $G(\alpha)$ empleando el hiperparámetro probabilidad de falsa alarma fija α mediante la ecuación (15).
 - 5: Obtener la matriz de residuos e_T mediante la ecuación (12) quedando el arreglo como sigue $e_T = \bar{X}_T - \hat{X}_{T2}$.
 - 6: Estimar $G(e_T)$ mediante la ecuación (15) y utilizando la desviación estándar de entrenamiento, se obtiene $G(e_T) = \sum_{i=1}^m \left[\frac{e_T}{\sigma_1} \right]^2$.
 - 7: Realizar comparación para conocer el estado de la máquina, si $G(e_T) > G(\alpha)$ la condición es de fallo, caso contrario, la condición es normal.
-

3.4. Validación del modelo

Finalmente, para validar la eficiencia del modelo de detección planteado se empleó el análisis mediante curva ROC. La finalidad de esta etapa fue distinguir la precisión del modelo de detección basado en análisis de componentes principales.

Para esta fase de validación se utilizó la probabilidad de falsa alarma, la cual cuantifica que tanto se equivoca el modelo de detección. Asimismo es necesaria la probabilidad de detección que cuantifica los aciertos que tiene el modelo basado en datos. Teniendo estas dos probabilidades se procedió a la construcción de la curva ROC para el modelo propuesto como se aprecia en la Figura 12.




Figura 12: Curva ROC en modelo basado en PCA. **Fuente:** Autor.

3.5. Sistema de detección de fallos en línea

Luego de la creación de la metodología propuesta para la detección de fallos y su respectiva evaluación, se realizó el diseño del sistema de detección en línea. Para la prueba de concepto se utilizó el compresor instrumentado en las instalaciones del GIDTEC. El modo de fallo que se le colocó al compresor para probar el sistema de detección en línea fue la condición P20.

Para el diseño e implementación del sistema de detección en línea se partió de la adquisición de señales de vibración en estado normal y en estado con fallo. En primer lugar, el sistema de adquisición de señales de vibración ya fue diseñado por miembros del GIDTEC en el software LabVIEW. El trabajo adicional que se realizó fue la introducción de la metodología propuesta para detectar fallos. La introducción se lo realizó agregando un bloque que

3. METODOLOGÍA PROPUESTA

ejecuta el algoritmo diseñado y muestra el estado del compresor luego de realizar la fase de inferencia descrita anteriormente.

El procedimiento que sigue el programa para la detección de fallos es el que se describe a continuación.

1. Se realiza la adquisición durante intervalos de 10 segundos dando como resultado una señal de 500k muestras.
2. Posteriormente se extraen 52 subseñales, con una ventana de 50000 muestras y un desplazamiento de 8600 muestras.
3. Las subseñales adquiridas son evaluadas mediante la fase de inferencia descrita anteriormente.
4. El estado de la máquina es mostrado en la ventana principal del programa junto con una gráfica de las componentes principales que explican el comportamiento de los datos de entrenamiento, en comparación con los datos adquiridos en línea. La ventana del programa se puede apreciar en la Figura 13.

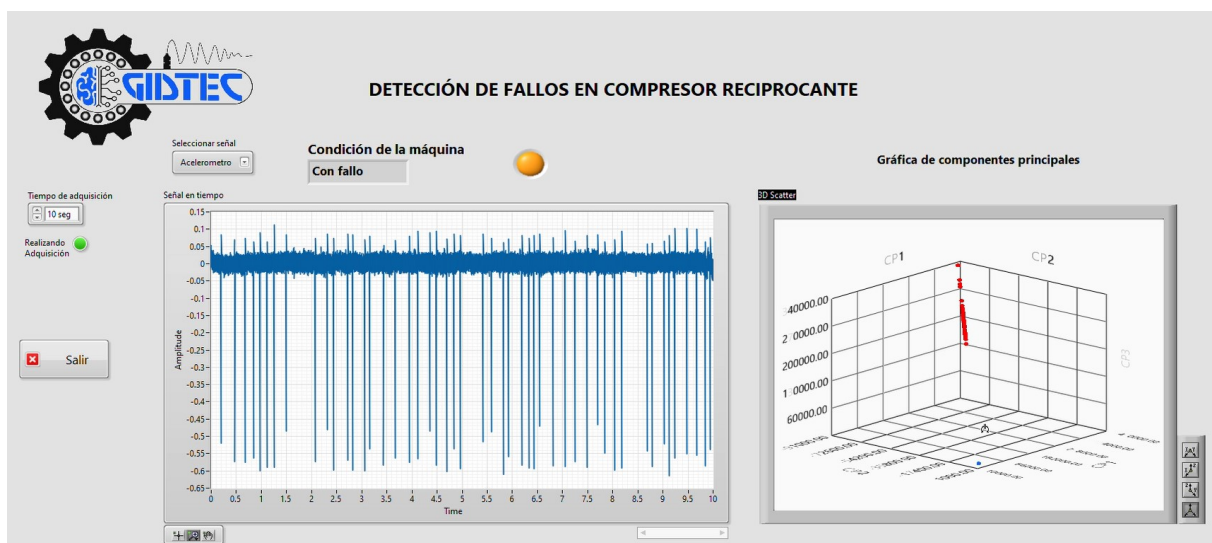


Figura 13: Propuesta de sistema de detección de fallos en línea para compresor recíprocante. **Fuente:** Autor.

4. ANÁLISIS DE RESULTADOS

En este capítulo se puede apreciar los resultados para el proceso de investigación, se muestra los resultados de la evaluación del modelo basado en PCA. Además, se muestra la implementación del sistema de detección en línea donde se aplica la prueba de concepto para la metodología planteada. Finalmente se realiza una discusión de los resultados propuestos.

4.1. Resultados de extracción de características

Aplicando la metodología propuesta por Guaman Buestan et al. (2018) para el incremento de señales de vibración colectadas se obtuvieron los siguientes resultados. Para la ventana de datos se dispuso de 50000 muestras, el retraso de 8600 muestras y el total de subseñales fue de 52 muestras que su organización se puede apreciar mediante la Figura 14.

Por otra parte para la etapa de extracción de características, los atributos útiles que mejor se relacionan entre si son: T2, T3, T4, T5, T8, T10, T12, T18, T19 que se describieron en la Tabla 4. Es importante agregar que para determinar cuales fueron estas características a escoger, se empleó la Tabla 5 y se observó que 9 de las 23 características superaban el valor de 0.8 de correlación entre pares de variables.




Figura 14: División de señal de vibración. **Fuente:** Autor.

Algunas consideraciones que se pueden denotar en la extracción de características es que es un paso fundamental para el entrenamiento del modelo, pues como se enunció, mientras las características tengan una alta correlación, el desempeño del modelado basado en análisis de componentes principales tiende a obtener mejores resultados.

4.2. Resultados del proceso de entrenamiento

El modelo de detección fue entrenado con un hiperparámetro de varianza porcentual acumulada del 90%. Como consecuencia se apreció que con 2 componentes principales se alcanzó un 94,52% de la varianza dadas las 9 componentes seleccionadas, los resultados correspondientes a esta etapa se muestran en la Figura 15.




Figura 15: Varianza porcentual acumulada por cada componente. **Fuente:** Propia.

Como se mencionó en un capítulo anterior, PCA puede reducir la dimensionalidad de los datos, en ese sentido se puede apreciar como 2 de las 9 características seleccionadas en el dominio del tiempo son suficientes para explicar el 94,52% de la varianza acumulada. Como consecuencia con estas dos componentes principales se logró entrenar al modelo de detección propuesto.

Por otra parte, el segundo hiperparámetro que se ajustó fue el nivel de significancia α o también llamada probabilidad de falsa alarma en los valores 0.05, 0.01 y 0.001. Como consiguiente se calculó el error dada la hipótesis binaria antes descrita. Para la condición P1 se determinó la tasa de falsos positivos pues se rechazó \mathcal{H}_0 siendo esta verdadera. Mientras que para el resto de condiciones de P2 a P25 también se determinó la tasa de falsos positivos pues se rechazó \mathcal{H}_1 siendo está verdadera.

Las pruebas efectuadas con los niveles de significancia acordados dan como resultado lo

4. ANÁLISIS DE RESULTADOS

mostrado en la Tabla 6, Tabla 7 y Tabla 8 respectivamente, en este conjunto de tablas podemos apreciar la tasa de falsos positivos dada la hipótesis compuesta. En concordancia con el resultado obtenido para los tres tipos de niveles de significancia, se puede evidenciar que existe una relación entre este nivel de significancia α y la tasa de falsos positivos. Ya que, mientras el nivel α disminuye, la tasa de falsos positivos también disminuye.

Posteriormente se graficó la curva ROC en los valores de significancia α entre (0.0000001 a 0.9999999) con la finalidad de determinar el nivel de significancia adecuado para el modelo de detección. Se pudo apreciar que el mejor valor de significancia es $\alpha = 0,0136$ que minimiza la tasa de falsos positivos y aumenta la tasa de verdaderos positivos descrito en la Figura 16.

Además, se determinó el área bajo la curva empleando integración numérica dando un valor de 0.872 correspondiente a la eficiencia del modelo de detección de fallos. Sirviéndonos del valor α más óptimo, se volvió a entrenar nuevamente al modelo de detección dando como resultado la Tabla 9 que muestra la tasa de falsos positivos del modelo al intentar detectar los fallos antes mencionados.

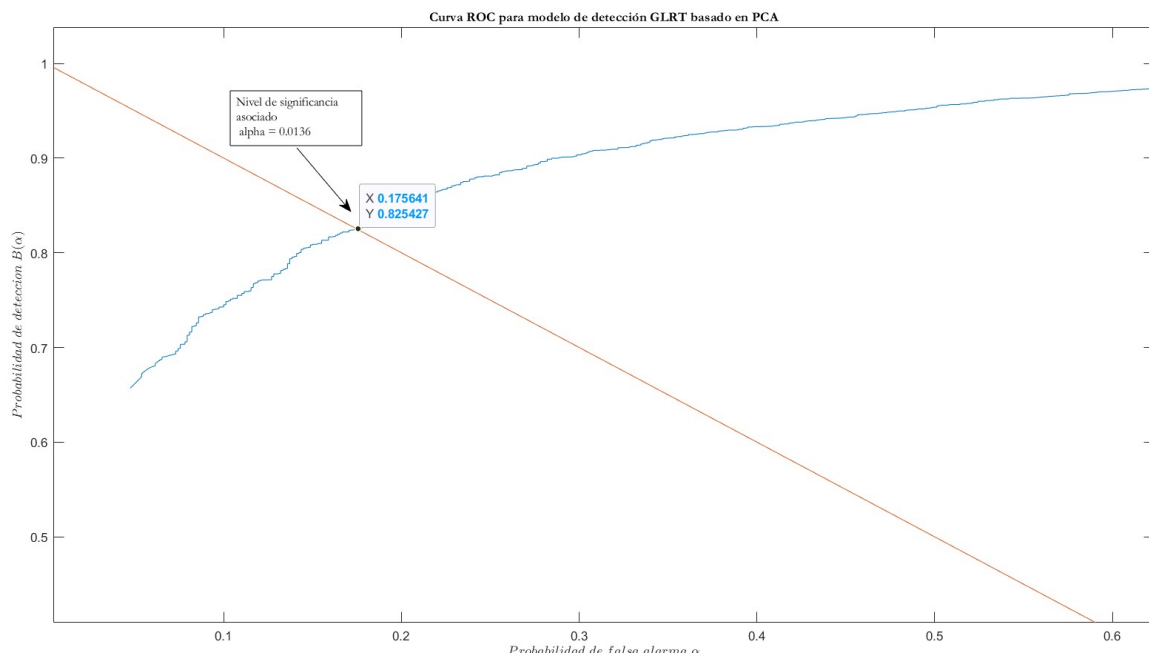


Figura 16: Curva ROC para modelo basado en PCA. **Fuente:** Autor.

Tabla 5: Matriz de correlación de características. Fuente: Autor.

Característica	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12	T13	T14	T15	T16	T18	T19	T20	T21	T22	T23
T1	1,00	0,04	0,04	0,04	0,05	0,01	0,09	0,04	0,01	0,04	0,04	0,02	-0,03	0,04	0,04	-0,02	-0,04	0,04	0,02	0,04	0,01	0,01
T2	0,04	1,00	1,00	1,00	0,54	0,47	0,53	0,34	0,63	0,39	0,04	0,70	-1,00	0,44	0,44	-0,43	-0,98	0,81	0,71	0,91	0,54	0,55
T3	0,04	1,00	1,00	1,00	0,55	0,47	0,54	0,34	0,63	0,39	0,05	0,70	-1,00	0,44	0,44	-0,44	-0,99	0,81	0,70	0,91	0,54	0,55
T4	0,04	1,00	1,00	1,00	0,55	0,47	0,54	0,34	0,63	0,39	0,05	0,70	-1,00	0,44	0,44	-0,44	-0,99	0,81	0,70	0,91	0,54	0,55
T5	0,05	0,54	0,55	0,55	1,00	0,85	0,78	0,96	0,63	0,98	0,85	0,27	-0,59	0,21	0,21	-0,41	-0,58	0,29	0,26	0,34	0,84	0,80
T6	0,01	0,47	0,47	0,47	0,85	1,00	0,63	0,84	0,80	0,85	0,69	0,04	-0,55	0,02	0,02	-0,60	-0,54	0,07	0,04	0,16	0,85	0,90
T7	0,09	0,53	0,54	0,54	0,78	0,63	1,00	0,72	0,55	0,74	0,60	0,27	-0,56	0,15	0,15	-0,40	-0,58	0,31	0,27	0,38	0,75	0,57
T8	0,04	0,34	0,34	0,34	0,96	0,84	0,72	1,00	0,57	0,99	0,94	0,08	-0,40	0,09	0,09	-0,39	-0,39	0,07	0,07	0,12	0,77	0,72
T9	0,01	0,63	0,63	0,63	0,63	0,80	0,55	0,57	1,00	0,61	0,35	-0,05	-0,69	-0,11	-0,11	-0,92	-0,73	0,08	-0,04	0,25	0,57	0,63
T10	0,04	0,39	0,39	0,39	0,98	0,85	0,74	0,99	0,61	1,00	0,93	0,10	-0,44	0,09	0,09	-0,43	-0,44	0,10	0,09	0,15	0,80	0,76
T11	0,04	0,04	0,05	0,05	0,85	0,69	0,60	0,94	0,35	0,93	1,00	-0,09	-0,10	-0,01	-0,01	-0,22	-0,09	-0,14	-0,10	-0,14	0,64	0,56
T12	0,02	0,70	0,70	0,70	0,27	0,04	0,27	0,08	-0,05	0,10	-0,09	1,00	-0,65	0,80	0,80	0,33	-0,60	0,97	1,00	0,90	0,27	0,24
T13	-0,03	-1,00	-1,00	-1,00	-0,59	-0,55	-0,56	-0,40	-0,69	-0,44	-0,10	-0,65	1,00	-0,41	-0,40	0,49	0,99	-0,77	-0,66	-0,87	-0,58	-0,61
T14	0,04	0,44	0,44	0,44	0,21	0,02	0,15	0,09	-0,11	0,09	-0,01	0,80	-0,41	1,00	1,00	0,39	-0,36	0,71	0,80	0,61	0,16	0,14
T15	0,04	0,44	0,44	0,44	0,21	0,02	0,15	0,09	-0,11	0,09	-0,01	0,80	-0,40	1,00	1,00	0,39	-0,36	0,71	0,80	0,61	0,16	0,14
T16	-0,02	-0,43	-0,44	-0,44	-0,41	-0,60	-0,40	-0,39	-0,92	-0,43	-0,22	0,33	0,49	0,39	0,39	1,00	0,56	0,16	0,33	-0,05	-0,38	-0,43
T18	-0,04	-0,98	-0,99	-0,99	-0,58	-0,54	-0,58	-0,39	-0,73	-0,44	-0,09	-0,60	0,99	-0,36	-0,36	0,56	1,00	-0,72	-0,60	-0,84	-0,56	-0,57
T19	0,04	0,81	0,81	0,81	0,29	0,07	0,31	0,07	0,08	0,10	-0,14	0,97	-0,77	0,71	0,71	0,16	-0,72	1,00	0,97	0,98	0,30	0,28
T20	0,02	0,71	0,70	0,70	0,26	0,04	0,27	0,07	-0,04	0,09	-0,10	1,00	-0,66	0,80	0,80	0,33	-0,60	0,97	1,00	0,90	0,27	0,24
T21	0,04	0,91	0,91	0,91	0,34	0,16	0,38	0,12	0,25	0,15	-0,14	0,90	-0,87	0,61	0,61	-0,05	-0,84	0,98	0,90	1,00	0,35	0,34
T22	0,01	0,54	0,54	0,54	0,84	0,85	0,75	0,77	0,57	0,80	0,64	0,27	-0,58	0,16	0,16	-0,38	-0,56	0,30	0,27	0,35	1,00	0,93
T23	0,01	0,55	0,55	0,55	0,80	0,90	0,57	0,72	0,63	0,76	0,56	0,24	-0,61	0,14	0,14	-0,43	-0,57	0,28	0,24	0,34	0,93	1,00

Tabla 6: Tasa de falsos positivos con nivel de significancia α 0.05 **Fuente:** Autor.

Repetición Condición	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15
P1	0,154	0	0,077	0,096	0,135	0,135	0,154	0,712	0,038	0,462	0,115	0,442	0	0,558	0,019
P2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P3	0,404	0,365	0	0,846	1	0,692	0,481	0	0,615	0	0,115	0,942	0,981	0,865	0,827
P4	0	0	0	0	0	0	0	0,058	0,327	0,385	0	0	0	0	0
P5	0	0	0	0	0	0	0	0	0	0	0,269	0,038	0,865	0,288	0,500
P6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P7	0	0	0	0	0	0	0	0	0	0	0,077	0,000	0,192	0	0,019
P8	0	0	0	0	0	0	0	0	0	0	0	0	0,038	0	0
P9	0	0	0	0,058	0,212	0,404	0	0	0	0,019	0,577	0,096	0	0	0
P10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P12	0,481	0,212	0	0	0	0	0	0	0	0	0	0	0	0	0
P13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P14	0,462	0,923	1	0,904	0,731	0,692	0,827	0,808	0,750	0,327	0,481	0,288	0,288	0,981	0,077
P15	0	0	0	0	0	0,038	0,538	0	0	0	0	0	0	0	0
P16	0	0	0,135	0,154	0,212	0,385	0	0	0,019	0	0,173	0,231	0,269	0	0,212
P17	0	0	0,096	0,231	0,692	0,038	0	0	0	0,038	0	0	0,115	0	0,058
P18	0	0	0,750	0,904	0,865	0,923	0,462	0,269	0,904	0,846	0,865	0,981	0,231	0,788	0,923
P19	0	0	0	0	0	0	0	0	0	0	0	0	0	0,019	0
P20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P21	0	0	0	0	0	0	0	0	0,135	0,038	0,038	0,615	0	0	0
P22	0,096	0,135	0	0,231	0,288	0,192	0,346	0	0	0,038	0	0	0,308	0,077	0,288
P23	0	0	0	0	0	0	0	0	0	0	0	0,038	0	0	0
P24	0	0,442	0,615	0,269	0,058	0,346	0,058	0	0,519	0	0	0	0,269	0,135	0,038
P25	0,538	0,904	0,519	0,865	0,481	0,769	0,808	0,750	1	0,327	0,885	0,750	0,808	0,731	0,654

Tabla 7: Tasa de falsos positivos con nivel de significancia α 0.01 **Fuente:** Autor.

Repetición Condición	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15
P1	0,115	0	0,058	0,038	0,115	0,058	0,115	0,615	0	0,404	0,077	0,365	0	0,500	0
P2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P3	0,519	0,500	0,019	0,981	1	0,808	0,577	0,000	0,712	0	0,308	0,981	1	0,942	0,904
P4	0	0	0	0	0	0,038	0	0,212	0,577	0,654	0	0	0	0	0
P5	0	0	0	0	0,019	0	0	0	0	0	0,442	0,096	0,923	0,346	0,577
P6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P7	0	0	0	0	0	0	0	0	0	0	0,096	0,077	0,308	0	0,058
P8	0	0	0	0	0	0	0	0	0	0	0	0	0,096	0	0
P9	0	0	0	0,135	0,385	0,635	0	0	0,115	0,038	0,962	0,115	0	0,019	0
P10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P12	0,577	0,288	0	0	0	0	0,019	0	0	0	0	0	0	0	0,096
P13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P14	0,519	1	1	0,904	0,846	0,865	0,885	0,865	0,846	0,442	0,615	0,308	0,346	1	0,192
P15	0	0	0	0,019	0	0,173	0,635	0	0	0,019	0,058	0	0	0	0
P16	0	0	0,231	0,423	0,365	0,673	0	0,019	0,135	0	0,423	0,558	0,596	0,058	0,423
P17	0	0	0,365	0,327	0,788	0,135	0	0	0,038	0,077	0	0,058	0,212	0	0,173
P18	0	0	0,846	0,962	0,923	0,962	0,538	0,462	0,923	0,885	1	1	0,385	0,808	1
P19	0	0	0	0	0	0	0	0	0	0	0	0	0,000	0,019	0
P20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P21	0	0	0	0	0	0	0	0	0,308	0,058	0,077	0,654	0	0	0
P22	0,115	0,308	0,000	0,365	0,404	0,212	0,404	0	0	0,058	0	0	0,500	0,135	0,442
P23	0	0	0	0	0	0	0	0,019	0	0	0	0,058	0	0,019	0
P24	0,058	0,692	0,673	0,346	0,115	0,519	0,135	0	0,654	0	0	0	0,346	0,250	0,058
P25	0,635	0,962	0,615	0,904	0,673	0,846	0,904	0,769	1	0,327	0,923	0,904	0,827	0,808	0,769

Tabla 8: Tasa de falsos positivos con nivel de significancia α 0.001 **Fuente:** Autor.

Repetición Condición	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15
P1	0,038	0	0,038	0,019	0,077	0,019	0,038	0,558	0	0,308	0,038	0,288	0	0,500	0
P2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P3	0,808	0,673	0,096	1	1	0,904	0,635	0	0,808	0	0,558	1	1	0,942	0,981
P4	0	0	0	0	0	0,115	0	0,538	0,769	0,865	0	0	0	0	0
P5	0	0	0	0	0,038	0	0	0	0	0	0,577	0,154	0,923	0,365	0,615
P6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P7	0,019	0,019	0	0	0,019	0	0	0	0	0	0,192	0,096	0,519	0,019	0,096
P8	0	0	0	0	0	0	0	0	0	0	0	0	0,115	0	0
P9	0	0	0	0,154	0,712	0,865	0	0	0,462	0,135	1	0,346	0	0,096	0
P10	0	0	0	0	0	0	0,038	0	0	0	0	0	0	0	0
P11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P12	0,769	0,423	0	0	0	0	0,019	0	0	0	0	0	0	0	0,192
P13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P14	0,654	1	1	0,923	0,981	0,962	0,904	0,885	0,962	0,558	0,769	0,308	0,500	1	0,423
P15	0	0	0	0,077	0,019	0,346	0,712	0	0	0,058	0,096	0	0	0	0
P16	0,019	0,058	0,404	0,673	0,538	0,885	0,019	0,038	0,442	0,058	0,731	0,808	0,885	0,115	0,596
P17	0	0	0,673	0,385	0,962	0,288	0	0,115	0,115	0,173	0,058	0,096	0,346	0	0,327
P18	0	0,058	0,846	1	0,923	0,962	0,635	0,615	0,962	0,942	1	1	0,519	0,865	1
P19	0	0	0	0	0	0	0	0	0	0	0	0	0	0,019	0
P20	0	0	0	0,019	0	0	0	0	0	0	0	0	0	0	0
P21	0	0	0	0	0	0	0	0	0,481	0,135	0,154	0,750	0	0	0
P22	0,173	0,558	0,019	0,481	0,538	0,442	0,577	0	0	0,077	0,019	0	0,577	0,250	0,558
P23	0	0	0,077	0	0	0	0	0,038	0	0,038	0,019	0,154	0	0,058	0
P24	0,192	0,769	0,827	0,385	0,192	0,712	0,173	0,115	0,788	0	0,019	0,038	0,519	0,500	0,058
P25	0,788	1	0,788	0,923	0,788	0,962	0,981	0,808	1	0,500	0,981	0,942	0,865	0,904	0,885

Tabla 9: Tasa de falsos positivos con nivel de significancia α 0.0136 **Fuente:** Autor.

Repetición Condición	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	R15
P1	0.115	0	0.058	0.058	0.115	0.077	0.115	0.635	0.019	0.423	0.096	0.404	0	0.5	0
P2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P3	0.5	0.442	0	0.942	1	0.808	0.538	0	0.7115	0	0.288	0.962	1	0.923	0.904
P4	0	0	0	0	0	0.038	0	0.154	0.5	0.654	0	0	0	0	0
P5	0	0	0	0	0.019	0	0	0	0	0	0.404	0.096	0.923	0.327	0.577
P6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P7	0	0	0	0	0	0	0	0	0	0	0.077	0.077	0.269	0	0.058
P8	0	0	0	0	0	0	0	0	0	0	0	0	0.077	0	0
P9	0	0	0	0.135	0.365	0.615	0	0	0.058	0.038	0.885	0.096	0	0.019	0
P10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P12	0.5769	0.288	0	0	0	0	0.0192	0	0	0	0	0	0	0	0.077
P13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P14	0.5192	1.000	1	0.904	0.846	0.846	0.885	0.865	0.846	0.385	0.596	0.308	0.346	1	0.192
P15	0	0	0	0.019	0	0.154	0.596	0	0	0.019	0.058	0	0	0	0
P16	0	0	0.192	0.346	0.308	0.596	0	0	0.135	0	0.385	0.481	0.538	0.038	0.423
P17	0	0	0.327	0.308	0.769	0.135	0	0	0.038	0.077	0	0.058	0.212	0	0.077
P18	0	0	0.827	0.942	0.923	0.962	0.538	0.423	0.923	0.865	0.981	1	0.365	0.788	1
P19	0	0	0	0	0	0	0	0	0	0	0	0	0	0.019	0
P20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
P21	0	0	0	0	0	0	0	0	0.25	0.058	0.077	0.654	0	0	0
P22	0.115	0.308	0	0.288	0.385	0.212	0.404	0	0	0.058	0	0	0.442	0.115	0.404
P23	0	0	0	0	0	0	0	0	0	0	0	0.058	0	0.019	0
P24	0.058	0.673	0.673	0.327	0.077	0.5	0.115	0	0.635	0	0	0	0.327	0.25	0.058
P25	0.635	0.962	0.615	0.904	0.635	0.846	0.904	0.769	1	0.327	0.904	0.885	0.827	0.788	0.769

4. ANÁLISIS DE RESULTADOS

Finalmente, la Tabla 10 resume la media de los errores para cada nivel de significancia y para cada modo de fallo. En la Tabla 10 se puede apreciar que para la condición normal (P1), es decir, la no presencia de fallos en válvulas, existe un valor para la media de la tasa de falsos positivos y esta disminuye a medida que el α disminuye.

Mientras que para los otros modos de fallo se puede apreciar que la media de la tasa de falsos positivos es nula para: P2 (Segunda etapa, válvula de descarga, desgaste en el asiento), P6 (Segunda etapa, válvula de succión, desgaste en el asiento), P10 (Primera etapa, válvula de descarga, desgaste en el asiento), P11 (Primera etapa, válvula de descarga, corrosión en el plato), P13 (Primera etapa, válvula de descarga, rotura del resorte), P20 (Segunda etapa, válvula de succión, fractura del plato) y (Segunda etapa, válvula de descarga, fractura del plato).

Sin embargo, la media de la tasa de falsos positivos supera el valor de (0.5) para los siguientes modos de fallo: P3 (Segunda etapa, válvula de descarga, corrosión en el plato), P14 (Primera etapa, válvula de succión b, desgaste en el asiento), P18 (Segunda etapa, válvula de succión, desgaste en el asiento) y (Segunda etapa, válvula de descarga, desgaste en el asiento), P25 (Primera etapa, válvula de succión, rotura del resorte) y (Segunda etapa, válvula de descarga, rotura del resorte).

En resumen, para la condición normal (P1) existe un valor de la media de la tasa de falsos positivos y para los 24 modos de fallo (P2-P25) restantes, se divide en: 6 modos de fallo presentan un valor cero para la media de la tasa de falsos positivos, por otra parte 4 modos de fallo superan el valor de (0.5) para la media de la tasa de falsos positivos y los restantes 14 modos de fallo tienen una media de la tasa de falsos positivos inferior a (0.5).

4. ANÁLISIS DE RESULTADOS

Tabla 10: Media de la tasa de falsos positivos para diferentes tipos de α . **Fuente:** Autor.

Condición \ Media con alpha	Media 0,05	Media 0,0136	Media 0,01	Media 0,001
P1	0.21	0.174	0.16	0.13
P2	0	0	0	0
P3	0.54	0.601	0.62	0.69
P4	0.05	0.090	0.1	0.15
P5	0.13	0.156	0.16	0.18
P6	0	0	0	0
P7	0.02	0.032	0.04	0.07
P8	0	0.005	0.01	0.01
P9	0.09	0.147	0.16	0.25
P10	0	0	0	0
P11	0	0	0	0
P12	0.05	0.064	0.07	0.09
P13	0	0	0	0
P14	0.64	0.703	0.71	0.79
P15	0.04	0.056	0.06	0.09
P16	0.12	0.229	0.26	0.42
P17	0.08	0.133	0.14	0.24
P18	0.65	0.703	0.71	0.76
P19	0	0.001	0	0
P20	0	0	0	0
P21	0.06	0.069	0.07	0.1
P22	0.13	0.182	0.2	0.28
P23	0	0.005	0.01	0.03
P24	0.18	0.246	0.26	0.35
P25	0.72	0.785	0.79	0.87

4.3. Resultados de sistema de detección de fallos en línea

Concretizando la investigación se logró comprobar la utilidad del algoritmo mediante una prueba de concepto aplicada al compresor. Para la verificación se utilizó un sistema de detección de fallos en línea, el cual recolecta datos tomados por un acelerómetro piezoeléctrico instrumentado en el compresor y ejecuta la metodología propuesta en el software LabView para mostrarnos la condición del equipo en tiempo real.

En la Figura 17 se puede apreciar la ventana del programa y su ejecución. Por otra parte, en la Figura 18 se puede apreciar el comportamiento de las componentes principales de acuerdo a los datos tomados, en color azul son las componentes que reflejan el entrenamiento y en

4. ANÁLISIS DE RESULTADOS

color rojo son las componentes que se toman en línea. Para la condición en fallo se utilizó la misma metodología de detección en línea en la Figura 19 apreciamos el panel principal y en la Figura 20 se muestran una gráfica de las tres componentes principales.



Figura 17: Sistema de detección de fallos en línea para compresor recíprocante en condición normal. **Fuente:** Autor.




Figura 18: Componentes principales para condición normal. **Fuente:** Autor.

4. ANÁLISIS DE RESULTADOS

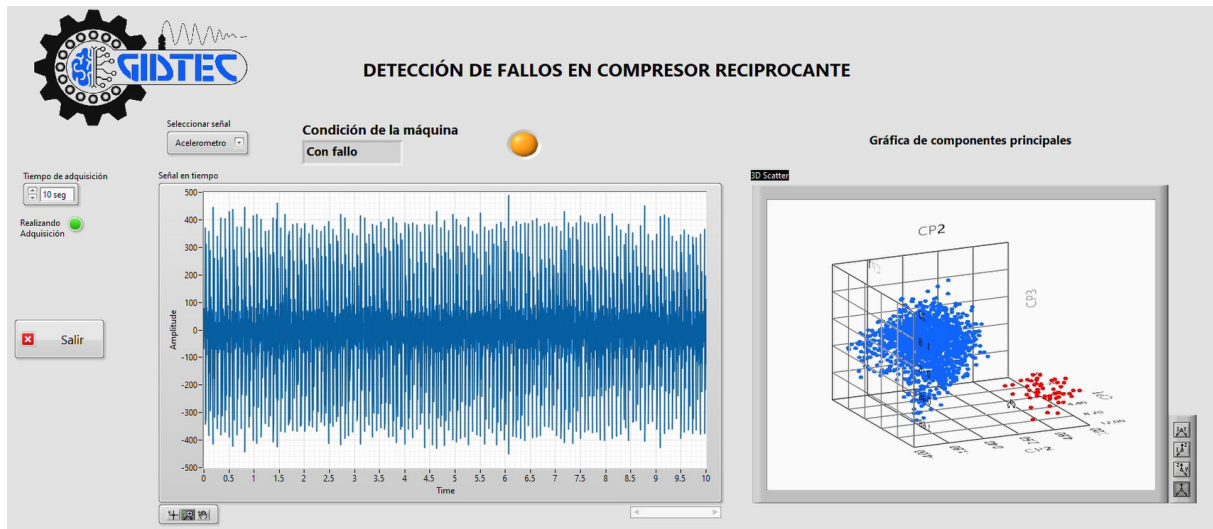


Figura 19: Sistema de detección de fallos en línea para compresor recíprocante en condición en fallo. **Fuente:** Autor.




Figura 20: Componentes principales para condición en fallo. **Fuente:** Autor.

CONCLUSIONES

- Mediante la integración de PCA junto a GLRT se pudo desarrollar un algoritmo capaz de detectar fallos en un compresor a partir de señales de vibración en condición normal. La utilidad del presente algoritmo se muestra en que no necesita de la presencia de un modelo del sistema para ser implementado.
- La metodología propuesta en el documento tiene una característica importante de resaltar y es que solamente utiliza PCA para expresar una matriz de datos como la suma de dos matrices, aproximada y residual. A continuación, se aplica GLRT a la matriz residual para detectar fallos cuando los datos no se ajustan al modelo PCA.
- El procesamiento de los datos para la fase de entrenamiento no contempla una carga computacional amplia.
- El algoritmo de detección de fallos desarrollado posee propiedades óptimas en el sentido de que maximiza la probabilidad de detección para una falsa alarma dado un nivel de significancia introducido.
- En síntesis, luego de realizar la experimentación se muestra que la fiabilidad del modelo alcanza el 87% del rendimiento mostrado mediante el área bajo la curva de probabilidad ROC.

RECOMENDACIONES Y TRABAJOS FUTUROS

- Se recomienda aplicar la presente metodología a otras partes esenciales del compresor como pueden ser fallos en rodamientos. Además, se recomienda utilizar otras condiciones de operación relacionadas a la presión al interior del tanque, en la presente investigación se empleó una presión de 3 bares. Se podría aumentar esta presión gradualmente como un trabajo complementario al que se expone.
- Para la fase de extracción de características se recomienda utilizar otro tipo de señales provenientes de la instrumentación del compresor, estas pueden ser de corriente o emisiones acústicas. A su vez, para esta fase se recomienda emplear otro dominio de análisis.
- Para finalizar se recomienda aplicar la metodología planteada a otros tipos de máquinas reciprocantes o rotatorias.

REFERENCIAS

- Ahmad, R., y Kamaruddin, S. (2012). An overview of time-based and condition-based maintenance in industrial application. *Computers & Industrial Engineering*, 63, 135-149. doi: 10.1016/J.CIE.2012.02.002
- Ahmed, M., Baqqar, M., Gu, F., y Ball, A. D. (2012). Fault detection and diagnosis using principal component analysis of vibration data from a reciprocating compressor. *Proceedings of 2012 UKACC International Conference on Control*, 461-466. doi: 10.1109/CONTROL.2012.6334674
- Bagavathiappan, S., Lahiri, B., Saravanan, T., Philip, J., y Jayakumar, T. (2013). Infrared thermography for condition monitoring—a review. *Infrared Physics & Technology*, 60, 35–55.
- Bevilacqua, M., y Braglia, M. (2000). The analytic hierarchy process applied to maintenance strategy selection. *Reliability Engineering & System Safety*, 70. doi: 10.1016/S0951-8320(00)00047-8
- Cajas Muñoz, F. D., y Torres Díaz, C. P. (2018). *Adquisición de señales acústicas y de vibración para el diagnóstico de fallos en un compresor recíprocante de doble etapa* (B.S. thesis).
- Coria, V., Maximov, S., Rivas-Dávalos, F., Melchor, C., y Guardado, J. (2015). Analytical method for optimization of maintenance policy based on available system failure data. *Reliability Engineering & System Safety*, 135. doi: 10.1016/j.res.2014.11.003
- Devendiran, S., y Manivannan, K. (2016). Vibration based condition monitoring and fault diagnosis technologies for bearing and gear components-a review. *American Journal of Mechanical Engineering*. doi: 10.12691/ajme-7-3-5
- Ferguson, T. S. (2014). *Mathematical statistics: A decision theoretic approach* (Vol. 1). Academic press.
- Fernández, P. (2000). *Compresores*. Verlag. Descargado de <https://pfernandezdiez.es/es/libro?id=9>
- García, D., y Fuente, M. J. (2011). Estudio comparativo de técnicas de detección de fallos basadas en el análisis de componentes principales (pca). *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 8, 182-195. doi: 10.1016/J.RIAI.2011.06.006
- García, S. (2010). *Organización y gestión integral de mantenimiento* (1.^a ed., Vol. 1; D. Santos, Ed.). Rústica.
- Goel, S., Ghosh, R., Kumar, S., y Akula, A. (2014). A methodical review of condition monitoring techniques for electrical equipment. En *National seminar & exhibition on non-destructive evaluation (nde 2014)*, pune.
- Guamán, A. d. P. (2019). Desarrollo de un modelo basado en datos a partir de señales de vibración para la detección de fallos en un compresor recíprocante de simple efecto doble etapa. *Universidad Nacional Mayor de San Marcos*.

- Guaman Buestan, A., Cabrera Mendieta, D., Sanchez Loja, R., Cerrada Lozada, M., y Cevallos Ampuero, J. (2018). Incremento del tamaño de los datos para la detección de fallos en maquinaria rotativa.. (IX Congreso Latinoamericano de Ingeniería Mecánica (COLIM 2018) ; Conference date: 07-12-2018)
- Guerra, C. J. (2013). *Condition monitoring of reciprocating compressor valves using analytical and data-driven methodologies*. Rochester Institute of Technology.
- Harrou, F., Nounou, M., y Nounou, H. (2012). Statistical detection of abnormal ozone levels using principal component analysis. *International Journal of Engineering & Technology*. doi: 10.1.1.419.6833
- Jackson, J. E., y Mudholkar, G. S. (1979). Control procedures for residuals associated with principal component analysis. *Technometrics*, 21(3), 341–349.
- Jardine, A. K., 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. doi: 10.1016/J.YMSSP.2005.09.012
- Jiang, Z., Zhang, J., Jin, M., y Ma, B. (2013). An expert system based on multi-source signal integration for reciprocating compressor. *WSEAS Transactions on Systems*, 12, 266-279.
- Jolliffe, I. (2002). *Principal component analysis* (2.^a ed.). Springer-Verlag. doi: 10.1007/b98835
- Kinnaert, M. (2003). Fault diagnosis based on analytical models for linear and nonlinear systems - a tutorial. *IFAC Proceedings Volumes*, 36, 37-50. doi: 10.1016/S1474-6670(17)36468-6
- Kothamasu, R., Huang, S. H., y VerDuin, W. H. (2006). System health monitoring and prognostics — a review of current paradigms and practices. *The International Journal of Advanced Manufacturing Technology*, 28. doi: 10.1007/s00170-004-2131-6
- Kresta, J., Macgregor, J., y Marlin, T. (1991). Multivariate statistical monitoring of process operating performance. *The Canadian Journal of Chemical Engineering*, 69. doi: 10.1002/cjce.5450690105
- Lane, S., Martin, E. B., Morris, A. J., y Gower, P. (2003). Application of exponentially weighted principal component analysis for the monitoring of a polymer film manufacturing process. *Transactions of the Institute of Measurement and Control*, 25. doi: 10.1191/0142331203tm071oa
- Lehmann, E. L., y Lehmann, E. (1986). *Testing statistical hypotheses* (Vol. 2). Springer.
- Loutas, T., Eleftheroglou, N., Georgoulas, G., Loukopoulos, P., Mba, D., y Bennett, I. (2020). Valve failure prognostics in reciprocating compressors utilizing temperature measurements, pca-based data fusion, and probabilistic algorithms. *IEEE Transactions on Industrial Electronics*, 67, 5022-5029. doi: 10.1109/TIE.2019.2926048
- Majdi, M., Mohamed, H., Hazem, N., y Mohamed, N. (2020). *Data-driven and model-based methods for fault detection and diagnosis* (1.^a ed.; A. Koch, Ed.). Elsevier. Descargado de <https://doi.org/10.1016/C2018-0-04213-9> doi: 10.1016/C2018-0-04213-9
- Medrano, J., González Ajuech, V., y Díaz de León Santiago, V. (2017). *Mantenimiento:*

- Técnicas y aplicaciones industriales*. Grupo Editorial Patria. Descargado de <https://books.google.com.ec/books?id=hZCDwAAQBAJ>
- Mina, J., y Verde, C. (2004). Detección de fallas usando análisis de componentes principales. *Congreso anual de la AMCA*.
- Misra, M., Yue, H. H., Qin, S. J., y Ling, C. (2002). Multivariate process monitoring and fault diagnosis by multi-scale pca. *Computers & Chemical Engineering*, 26, 1281-1293. doi: 10.1016/S0098-1354(02)00093-5
- Mobley, K. (2002). *An introduction to predictive maintenance*. Elsevier. doi: 10.1016/B978-0-7506-7531-4.X5000-3
- Mora, L. (2009). *Mantenimiento - planeación, ejecución y control*. Alpha Editorial. Descargado de <https://books.google.com.ec/books?id=TYc3DQAAQBAJ>
- Nandi, A., y Ahmed, H. (2019). *Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines*. John Wiley & Sons, Incorporated. Descargado de <https://books.google.com.ec/books?id=SF1QzQEACAAJ>
- Peña, D. (2002). *Análisis multivariante de datos*. McGraw-Hill Interamericana de España S.L. Descargado de <https://books.google.com.ec/books?id=TrVlAAAACAAJ>
- Peng, L., Han, G., Pagou, A. L., y Shu, J. (2020). Electric submersible pump broken shaft fault diagnosis based on principal component analysis. *Journal of Petroleum Science and Engineering*, 191, 107154. doi: 10.1016/J.PETROL.2020.107154
- Pichler, K., Lughofer, E., Pichler, M., Buchegger, T., Klement, E. P., y Huschenbett, M. (2016). Fault detection in reciprocating compressor valves under varying load conditions. *Mechanical Systems and Signal Processing*, 70-71, 104-119. Descargado de <https://www.sciencedirect.com/science/article/pii/S0888327015004008> doi: <https://doi.org/10.1016/j.ymsp.2015.09.005>
- Portnoy De la Ossa, I. D., y cols. (2014). Diseño de un método adaptativo de detección temprana de fallas para la reducción de falsas alarmas debidas al envejecimiento de procesos ya la incertidumbre estadística. *Avances Tomo A*.
- Potočnik, P., y Govekar, E. (2017). Semi-supervised vibration-based classification and condition monitoring of compressors. *Mechanical Systems and Signal Processing*, 93, 51-65. doi: 10.1016/J.YMSSP.2017.01.048
- Qi, G., Zhu, Z., Erqinhu, K., Chen, Y., Chai, Y., y Sun, J. (2018). Fault-diagnosis for reciprocating compressors using big data and machine learning. *Simulation Modelling Practice and Theory*, 80, 104-127. doi: 10.1016/J.SIMPAT.2017.10.005
- Randall, R. B. (2011). *Vibration-based condition monitoring: Industrial, automotive and aerospace applications*. (1.^a ed.). John Wiley & Sons.
- Sánchez Loja, R. V. (2017). Diagnóstico de fallos en cajas de engranajes mediante la aplicación de diferentes técnicas de inteligencia artificial. *Universidad Nacional de Educación a Distancia (España). Escuela . . .*
- Tsang, A. H. (1995). Condition-based maintenance: tools and decision making. *Journal of Quality in Maintenance Engineering*, 1. doi: 10.1108/13552519510096350
- Uluyol, O., Kim, K., y Nwadiogbu, E. O. (2006). Synergistic use of soft computing

- technologies for fault detection in gas turbine engines. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 36, 476-484. doi: 10.1109/TSMCC.2006.875415
- Usmani, N., Velisetti, S., Tiwari, P., Mishra, S., Kumar, S., y Patnaik, U. (2018). Chatter detection using principal component analysis in cold rolling mill. *Diagnostyka*, 19. doi: 10.29354/diag/81692
- Verma, N. K., Sevakula, R. K., Dixit, S., y Salour, A. (2016). Intelligent condition based monitoring using acoustic signals for air compressors. *IEEE Transactions on Reliability*, 65, 291-309. doi: 10.1109/TR.2015.2459684
- Villacís Marín, M. L. (2020). *Modelamiento basado en datos para la detección de fallos en una bomba hidráulica centrífuga multietapa vertical a partir de señales multimodales en condición normal* (Tesis de Master no publicada). Norges teknisk-naturvitenskapelige universitet.
- Waarli, M. (2010). *Performance monitoring of compressors with electrical drive* (Tesis de Master no publicada). Norges teknisk-naturvitenskapelige universitet, Fakultet for
- Yang, M. (2009). Air compressor efficiency in a vietnamese enterprise. *Energy Policy*, 37, 2327-2337. doi: 10.1016/J.ENPOL.2009.02.019
- Zhang, Y., y Zhang, L. (2022). Intelligent fault detection of reciprocating compressor using a novel discrete state space. *Mechanical Systems and Signal Processing*, 169, 108583. Descargado de <https://www.sciencedirect.com/science/article/pii/S088832702100916X> doi: <https://doi.org/10.1016/j.ymsp.2021.108583>
- Zhou, W., Habetler, T. G., y Harley, R. G. (2007). Bearing condition monitoring methods for electric machines: A general review. En *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives* (p. 3-6). doi: 10.1109/DEMPED.2007.4393062
- Zhu, S., Xia, H., Annor-Nyarko, M., Yin, W., Peng, B., Wang, Z., y Zhang, J. (2021). A robust strategy for sensor fault detection in nuclear power plants based on principal component analysis. *Annals of Nuclear Energy*, 164, 108621. doi: 10.1016/J.ANUCENE.2021.108621