



**UNIVERSIDAD AUTÓNOMA DE QUERÉTARO**  
**FACULTAD DE INGENIERÍA**

**DIVISIÓN DE INVESTIGACIÓN Y POSGRADO**  
**Maestría en Ciencias en Mecatrónica**

**Sensor inteligente basado en técnicas de tiempo-frecuencia para supervisión de fallas  
en cojinetes cerámicos y metálicos**

**TESIS**

Que como parte de los requisitos para obtener el grado de  
**Maestro en Ciencias en Mecatrónica**

Presenta:

**Ing. Mayra Ramírez Chávez**

Dirigido por:

**Dr. Rene de Jesús Romero Troncoso**

**Dr. Miguel Delgado Prieto**

Campus San Juan del Rio, Querétaro, México, Noviembre 2019.

Dirección General de Bibliotecas UAQ



**UNIVERSIDAD AUTÓNOMA DE QUERÉTARO**  
**FACULTAD DE INGENIERÍA**

**DIVISIÓN DE INVESTIGACIÓN Y POSGRADO**  
**Maestría en Ciencias en Mecatrónica**

**Sensor inteligente basado en técnicas de tiempo-frecuencia para supervisión de fallas  
en cojinetes cerámicos y metálicos**

**TESIS**

Que como parte de los requisitos para obtener el grado de  
**Maestro en Ciencias en Mecatrónica**

Presenta:

**Ing. Mayra Ramírez Chávez**

Dirigido por:

**Dr. Rene de Jesús Romero Troncoso**

Co-dirigido por:

**Dr. Miguel Delgado Prieto**

**Dr. Rene de Jesús Romero Troncoso**

Presidente

**Dr. Roque Alfredo Osornio Ríos**

Secretario

**Dr. Juan José Saucedo Dorantes**

Vocal

**Dr. Miguel Delgado Prieto**

Suplente

**Dr. Luis Morales Velázquez**

Suplente

Centro Universitario, Querétaro, Qro.  
Noviembre 2019  
México

Dirección General de Bibliotecas UAQ

## RESUMEN

La presente tesis redacta el análisis y evaluación de una metodología novedosa propuesta para desarrollar un sensor inteligente que detecte fallas en rodamientos metálicos y cerámicos de motores de inducción mediante la implementación de técnicas tiempo-frecuencia. Esta redacción cuenta con dos procedimientos, el primero, se basa en las pruebas y el segundo en la implementación del sensor.

Después de la revisión de artículos, se detectó que la mayoría de los autores dedicados al estudio de detección de fallas en rodamientos, se rigen de una base de datos en línea llamada “*Case Western Reserve University Bearing Data Center Website*”. Por lo que algunas pruebas fueron desarrolladas usando esta base de datos. En algunos otros artículos desarrollaban sus propias fallas, por lo que se optó en fabricar fallas de la misma magnitud en rodamientos metálicos y cerámicos. Después de la fabricación de fallas de 1mm y 2mm en la pista interior de los dos rodamientos, se realizó una base de datos que contiene las señales de vibración y corriente de los rodamientos en estado sano y con dos severidades de falla a diferentes velocidades de rotación.

Para el procedimiento utilizado en las pruebas de las técnicas implementadas, el procesamiento de señales fue utilizado en primera parte para la segmentación que consta en dividir el vector adquirido en ciertos tramos de señal. Posteriormente se analiza cada tramo de señal por separado utilizando indicadores estadísticos en el dominio de tiempo, después de realizar los cálculos de los 8 indicadores sugeridos por la literatura en cada segmentación de la señal se realiza un proceso de normalización. al finalizar este proceso, la matriz de datos es sometida a un proceso de reducción característica mediante el análisis de componentes principales (PCA) y el análisis discriminante lineal (LDA) para después concluir con un entrenamiento de un clasificador basado en el algoritmo K-Vecinos más cercanos (KNN).

**(Palabras clave: sensor inteligente, reducción de características, clasificación, detección de fallas, cálculos característicos)**

## SUMMARY

This thesis writes the analysis and evaluation of a novel methodology proposed to develop an intelligent sensor that detects failures in metallic and ceramic bearings of induction motors through the implementation of time-frequency techniques. This wording has two procedures, the first one is based on the tests and the second one on the sensor implementation.

After reviewing articles, it was found that most authors dedicated to the study of bearing failure detection are governed by an online database called "Case Western Reserve University Bearing Data Center Website". So some tests were developed using this database. In some other articles they developed their own failures, so it was decided to manufacture faults of the same magnitude in metallic and ceramic bearings. After manufacturing 1mm and 2mm faults in the inner race of the two bearings, a database containing the vibration and current signals of the bearings in a healthy state and with two severities of failure at different rotation speeds was made.

For the procedure used in the tests of the implemented techniques, the signal processing was used in the first part for the segmentation that consists in dividing the acquired vector into certain signal sections. Subsequently, each section of the signal is analyzed separately using statistical indicators in the time domain, after performing the calculations of the 8 indicators suggested by the literature in each segmentation of the signal a normalization process is performed. At the end of this process, the data matrix is subjected to a features reduction process through principal component analysis (PCA) and linear discriminant analysis (LDA) and then concludes with a training of a classifier based on the K-Neighbors algorithm closest (KNN).

**(Keywords: smart sensor, features reduction, classification, fault detection, feature calculations)**

## AGRADECIMIENTOS

Esta es la primera tesis que realizo, por lo cual, tuve tantas dudas e inseguridades sobre mi trabajo, en el transcurso de la maestría me he encontrado con personas muy inteligentes y capaces, en varias situaciones me preguntaba que hacia dentro de este programa, en realidad para mí fue muy pesado, ya que pienso que no tenía las bases tan fuertes como los demás, sin embargo, trataba de no enfocarme en ello si no en lo poco que podía aprender con la ayuda de las personas que estaba rodeada y de las cuales nunca recibí algún mal trato sino todo lo contrario.

Por lo que agradezco a Dios, por darme la oportunidad de experimentar el lado de la investigación y la docencia.

A CONACYT, por darme los recursos para poder estar dentro de este programa ya que sin su apoyo esto no fuera posible.

A mis profesores, pero sobre todo a mis sinodales, por aclarar con toda paciencia cada una de mis dudas: Al equipo de trabajo MCIA, especialmente a Miguel y Romeral ya que me han recibido con los brazos abiertos, dedicaron parte de su tiempo en orientarme, se preocuparon de cómo estaba y me dieron tantos consejos tanto académicos como personales.

A toda mi familia y sobre todo a mis padres, por respaldarme y darme las fuerzas que necesito al recordarme lo importante que soy en sus vidas y lo que ellos son en la mía, mi madre por ser el mejor ejemplo de esfuerzo, persistencia y amor.

A mis amistades, por hacerme saber que no importa el tiempo ni la distancia, que por más estresada que estuviera algún mensaje me reseteaba.

Finalmente, a KMGS, por estar en las buenas, en las malas y en las peores, siempre al pendiente de que necesito y sobre todo de como estoy, por llevarme por el buen camino y regañarme cuando las cosas no van bien en mí, por enseñarme a amar y apasionarme por mi trabajo.

Gracias.

## INDICE

RESUMEN.....	i
SUMMARY .....	ii
AGRADECIMIENTOS .....	iii
INDICE .....	iv
INDICE DE FIGURAS .....	v
INDICE DE TABLAS .....	vii
1. INTRODUCCIÓN.....	1
1.1 ANTECEDENTES .....	1
1.2 DESCRIPCIÓN DEL PROBLEMA.....	6
1.3 JUSTIFICACIÓN .....	7
1.4 HIPÓTESIS .....	8
1.5 OBJETIVOS.....	8
2. FUNDAMENTACIÓN TEÓRICA .....	10
2.1 INTRODUCCIÓN.....	10
2.2 MOTORES DE INDUCCIÓN (MI).....	12
2.3 ADQUISICIÓN DE SEÑALES .....	26
2.4 APRENDIZAJE AUTOMÁTICO.....	31
2.5 REDUCCIÓN DE CARACTERÍSTICAS .....	43
2.6 CLASIFICACIÓN.....	47
3. METODOLOGÍA .....	53
4. RESULTADOS Y DISCUSIONES .....	65
5. CONCLUSIONES.....	83
6. REFERENCIA BIBLIOGRÁFICA.....	85

## INDICE DE FIGURAS

Figura 1. a) Consumo eléctrico mundial. b) Uso de MI (Autoría propia) .....	12
Figura 2. Partes de un motor de inducción (MI) .....	15
Figura 3. Placa característica de un motor trifásico.....	16
Figura 4. Desalineamiento angular.....	17
Figura 5. Desalineamiento paralela .....	17
Figura 6. Tipos de excentricidad .....	19
Figura 7. Partes de un rodamiento.....	20
Figura 8. Ejemplo de frecuencia de falla en un rodamiento .....	20
Figura 9. Rodamientos cerámicos e híbridos .....	23
Figura 10. Comparación de dilatación lineal.....	24
Figura 11. Comparación de temperatura .....	24
Figura 12. Comparación de desgaste.....	25
Figura 13. Comparación de rigidez axial .....	25
Figura 14. Diagrama de un sensor inteligente .....	29
Figura 15. Diagrama de aprendizaje supervisado.....	32
Figura 16. Diagrama de aprendizaje no supervisado.....	33
Figura 17. Envolturas de la EMD .....	41
Figura 18. Wavelet Daubechies (www.mathworks.com).....	42
Figura 19. Interpretación de la STFT (Rao et al., 2011) .....	43
Figura 20. Los dos componentes principales más importantes .....	44
Figura 21. Clasificación con K vecinos más cercanos .....	48
Figura 22. Neurona biológica.....	49
Figura 23. Sinapsis de una neurona biológica .....	50
Figura 24. Esquema de una neurona artificial .....	52
Figura 25. Diagrama de la metodología general propuesta .....	54
Figura 26. Banco de pruebas previo .....	54
Figura 27. Banco de pruebas utilizado .....	55
Figura 28. Placa característica del motor utilizado.....	55
Figura 29. Sensores Utilizados (Acelerómetro y pinzas de corriente) .....	56
Figura 30. NI PXIe-1062Q.....	57
Figura 31. Plataforma LabVIEW SignalExpress.....	58
Figura 32. Plataforma de MATLAB .....	59
Figura 33. Segmentación.....	61

Figura 34. Representación de PCA .....	63
Figura 35. Algoritmo KNN .....	64
Figura 36. Diagrama a bloques del proceso del caso 1 .....	67
Figura 37. Caso I. a) Datos de entrenamiento, b) Datos de validación .....	68
Figura 38. Caso II. a) Datos de entrenamiento, b) Datos de validación .....	69
Figura 39. Caso III. a) Datos de entrenamiento, b) Datos de validación.....	71
Figura 40. Diagrama de proceso del análisis de fallas en rodamientos metálicos y cerámicos .....	72
Figura 41. Fabricación de fallas en rodamientos .....	73
Figura 42. Estados de fallas en rodamientos metálicos .....	73
Figura 43. Estado de fallas en rodamientos cerámicos.....	74
Figura 44. Montaje de rodamiento en el motor con falla a las 12:00 .....	76
Figura 45. Clasificación en rodamientos metálicos.....	77
Figura 46. Clasificación en rodamientos cerámicos .....	78
Figura 47. Resultado de rodamientos metálicos con técnica tiempo-frecuencia .....	79
Figura 48. Figura 47. Resultado de rodamientos cerámicos con técnica tiempo-frecuencia.....	80
Figura 49. Diagrama esquemático del sensor inteligente propuesto .....	81

## INDICE DE TABLAS

Tabla 1. RPM de un MI según sus números de pares de polos .....	14
Tabla 2. Diferencia de velocidades .....	14
Tabla 3. Frecuencias características de fallas en rodamientos de bola .....	21
Tabla 4. Cálculos característicos estadístico-temporales utilizados .....	62
Tabla 5. Datos de entrenamiento vs datos de validación.....	68
Tabla 6. Matriz de confusión caso I .....	69
Tabla 7. Matriz de confusión caso II .....	70
Tabla 8. Matriz de confusión caso III.....	71
Tabla 9. Velocidades del motor.....	74
Tabla 10. Matriz de confusión de rodamientos metálicos .....	77
Tabla 11. Matriz de confusión de rodamientos cerámicos .....	78
Tabla 12. Matriz de confusión del análisis tiempo-frecuencia de rodamientos metálicos .....	80
Tabla 13. Matriz de confusión del análisis tiempo-frecuencia de rodamientos cerámicos.....	81

# CAPÍTULO I

## 1. INTRODUCCIÓN

### 1.1 ANTECEDENTES

El desarrollo de nuevas tecnologías enfocadas en la solución de problemas en aplicaciones de la industria moderna ha presentado un fuerte auge en los últimos años, esto debido a que la mayoría de esfuerzos se concentran en asegurar el correcto funcionamiento de la maquinaria, y también debido al papel tan importante que juegan cada uno de los componentes que conforman una maquinaria industrial. El trabajo escrito por Villalobos (2015) menciona que la maquinaria eléctrica rotatoria representa el primordial origen de movimiento en la zona fabril y se han aplicado en prácticamente cualquier área del quehacer cotidiano como sistemas de producción, transporte aéreo, marítimo, terrestre, aires acondicionados, transformación de energía e incluso sistemas de vibración, esto incluye los teléfonos celulares. Los motores de inducción (MI) se conocen como los motores más resistentes empleados en la industria. Su robustez y eficiencia lo hace ser un motor casi exclusivo, empleado para la transformación de energía eléctrica a mecánica; debido a su alto uso, cerca del 90% del consumo energético se debe a este tipo de motores. Incluso, cerca del 60% de los motores eléctricos utilizados por la industria son de este tipo, ya que no necesitan de un mantenimiento constante. En investigaciones recientes, se especifican las distribuciones de las fallas del MI y las consecuencias después que la falla sucede especificando el proceso de decisión-reemplazo. Las distribuciones de fallas son las siguientes: fallas en los baleros (69%) fallas en el rotor (7%), fallas en el estator (21%), y fallas relacionadas con el cople, la flecha, y otras (3%). Según Medrano-Hurtado (2016) otro elemento fundamental en las máquinas electromecánicas rotatorias es el generador. El generador síncrono genera aproximadamente el 99% del consumo de electricidad en el mundo, debido a dicha estimación en la generación eléctrica global, es necesario el adelanto

al acontecimiento de fallas que produzcan problemas indeseados en el proceso. Este generador se encuentra expuesto a numerosas fallas y constituye el conjunto más costoso de los sistemas eléctricos de potencia, lo que lo coloca en una crítica posición establecida. En este generador síncrono, las fallas en los rodamientos son unos de los problemas más comunes. Aproximadamente el 40% de las fallas en las máquinas eléctricas rotativas.

Como se ve en los registros en fallas de maquinaria electromecánica rotativa, el mayor número de problemas se encuentra en los cojinetes. Medrano-Hurtado (2016) dice que las principales causas que inducen fallas en rodamientos suelen ser debido a: lubricaciones inadecuadas 36%; operaciones inadecuadas (carga dinámica excesiva o presencia de fuerza externa como desbalances o desalineamientos) 34%; contaminación, incluyendo humedad 14%; defecto original en el proceso de montaje: mal manejo, causado por la transportación, el almacenamiento o la instalación inadecuada del rodamiento 16%. En la mayor parte de los casos, la falla no aparece de forma inesperada sino gradualmente, esto hace factible detectar las fallas previo a que el proceso resulte desastroso. En un estudio hecho por fabricantes, fue concretado que los rodamientos ejecutan el 80% aproximadamente de su vida útil libres de anomalías, al ocurrir una falla, normalmente se clasifican en una de las cuatro siguientes etapas de fallas: Primera etapa: vibraciones con componentes de alta frecuencia debido a las generaciones de ondas de esfuerzo; Segunda etapa: comienzan a aparecer grietas que son visibles para al ojo humano y los rodamientos presentan emisiones acústicas además la temperatura incrementa en ocasiones; Tercera etapa: acorde avanza la fisura, aparecen bandas laterales en torno a las frecuencias de fallas relacionadas con la velocidad de rotación y modulación entre ellas. En esta etapa se programa el remplazo de los rodamientos; Cuarta etapa: Se acercan fallas catastróficas, aumenta la emisión acústica y genera sobrecalentamiento.

Por otra parte, los sensores son de gran importancia para cuantificar la vida útil de la maquinaria y asegurar su disponibilidad en aplicaciones del sector industrial. Según Cárdenas (2013), los sensores primarios son dispositivos capaces de captar magnitudes fisicoquímicas conocidas como variables de instrumentación, después transformarlas en variables eléctricas o de otra naturaleza. El sensor analógico, se requiere donde los

fenómenos a percibir son variables con el tiempo, en esos casos, los sensores son unos transductores y se conectan a una entrada particular con un instrumento convertidor analógico-digital. Por otro lado, los sensores inteligentes son un sistema general de control y adquisición de datos como resultado de un desempeño mejorado, si se toma en cuenta los costos de ciclo de vida, mantenimiento y conexión. Proveen características que son requeridas de tal forma que se puedan expandir las aplicaciones de tecnologías de sensado en una manera económica tales como: “Hoja de datos” electrónica, Auto identificación, calibración inteligente y compensación, información digital de la señal sensada y comunicación del sensor para propósitos de monitoreo y configuración remota. Una de las ventajas técnicas que influyen en el uso de los sensores inteligentes es su uso en redes, verificando su operación en rangos definidos por el fabricante y validando que está operando dentro de un ambiente permitido y en general que se determine que es funcional.

Hoy en día, existen algunos trabajos que desarrollaron sensores inteligentes para diferentes aplicaciones, como es el de Vera-Salas et al (2011), quienes realizaron un sensor inteligente para mediciones de gran desplazamiento basado en la medición de fase que logra una alta precisión y resolución, fue diseñado para ser utilizado con un interferómetro heterodino comercial. Millán-Almaraz et al (2010), propusieron un sensor inteligente que consta de cinco sensores primarios que miden la temperatura a la que se encuentra la hoja, la humedad relativa y la temperatura que se tiene en el aire, la humedad relativa de la planta y la luz del ambiente, esto permite al usuario observar diferentes medidas primarias y calculadas al mismo tiempo y la relación entre ellas que es muy útil en la precisión y detección de condiciones anormales de la agricultura. La contribución del trabajo de Moreno-Tapia et al (2010), es el estudio de una plataforma de red inalámbrica que consta de cuatro sensores inteligentes diferentes y reconfigurables, para aplicaciones como monitoreo de máquinas de nueva generación controladas numéricamente. Por último, Rodríguez-Donate et al (2010), presentaron un sensor inteligente para estimar la dinámica de movimiento, la inclinación y los parámetros de vibración en los enlaces de robots manipuladores industriales basados en dos sensores principales: un codificador y un acelerómetro triaxial, basado en arreglos de compuertas programables de campo.

La cuantificación de diferentes magnitudes físicas ha sido la clave de la mayoría de metodologías de diagnóstico propuestas, Quiceno (2009) plantea que las señales aportan datos que representan las medidas de los sistemas del mundo real, por ejemplo, la vibración de un motor, una onda sísmica, un factor atmosférico o simplemente bioseñales. Villa (2016) dice que para procesar estas señales ha sido muy utilizado el análisis en el dominio en el tiempo, también ha resultado muy bueno disponer de una representación en el dominio frecuencial, por permitir extraer particularidades que no tienden a ser claras en el dominio del tiempo y colaboran a entender su naturaleza; en tanto el dominio en el tiempo aporta información acerca de cómo cambiar la amplitud de la señal a lo largo del tiempo, el dominio de la frecuencia muestra con qué frecuencia suceden las variaciones. Según Quiceno (2009) procesar las señales da origen a muchas aplicaciones, que incluye: modulación, detección, estimación, análisis, caracterización o modelado, síntesis, filtrado, clasificación, codificación, supresión, sincronización y ecualización.

Una herramienta típica de desarrollo para este procesamiento es la transformada de Fourier, es usada para extraer información frecuencial comenzado con la señal en el dominio temporal. A pesar del valioso uso en un enorme rango de aplicaciones, la teoría de Fourier frecuentemente tiene restricciones propias, provienen de las señales procesadas. Procesar y analizar señales de tiempo-frecuencia se emplean a señales con contenido frecuencial y que varía en el tiempo. Estas señales se representan a través de una distribución tiempo-frecuencia (TFD Time-Frequency Distribution), esta muestra la manera en que se divide la energía de la señal en un entorno bidimensional tiempo-frecuencia. Así, en el procesamiento de las señales, se aprovechan las particularidades elaboradas por la acumulación de energía bidimensional (tiempo y frecuencia) en lugar de tener solo una (tiempo o frecuencia). La idea de procesamiento en el dominio tiempo-frecuencia fue de Wigner que aporta la distribución Wigner (WD-Wigner Distribution) en 1932, cuando dio el concepto de mecánica cuántica como la función del momento y la posición. Esta distribución fue redefinida en 1948 por Ville (WVD-Wigner-Ville Distribution) en contexto de señales, como una función de tiempo y frecuencia. Por otra parte, se introdujo la representación de señales habladas gracias al espectrógrafo de sonido en 1946. esto es relacionado con la transformada en tiempo corto de

Fourier (STFT Short Time Fourier Transform) (o su magnitud, el espectrograma) debido que se asume que la señal es estacionaria en una ventana de tiempo pequeña, en la cual, la transformada de Fourier de segmentos consecutivos en el tiempo dan una representación adecuada de la señal. Cohen en 1966, planteo una clase completa de distribuciones tiempo-frecuencia basadas en la WVD, y enfatizó el interés en el procesamiento de señales. El espectrograma y la WVD son las representaciones que más se utilizan para el análisis tiempo-frecuencia por la simplicidad en teoría e implementación.

Debido a la importancia de las máquinas electromecánicas rotativas en la vida diaria, y que la mayoría de las fallas en la industria es debido a dicha maquinaria, se han registrado algunos trabajos que han ayudado a localizar fallas en esas máquinas para el mantenimiento preventivo correcto, logrando así, evitar los mantenimientos correctivos por el mayor costo que esto implica. Dentro de los trabajos relacionados con la localización de fallas se encontró el de Medrano-Hurtado (2015) quien dio a conocer una metodología novedosa para la detección de fallas en rodamientos, empleando señales de vibración capturadas a través de transductores de aceleración y acústicos, para procesar la señal, se aplica un algoritmo que se conoce como densidad espectral de potencia (PSD). Este método permitió la utilización de micrófonos para analizar la vibración de las máquinas lo que representa no tener que montar ningún transductor como ocurre al utilizar acelerómetros. Otro trabajo fue el de Magallán (2009) quien aplicó diferentes técnicas de filtrado o cancelación de interferencia armónica en señales de medición para la detección de fallas en motores eléctricos. El objetivo fue eliminar de las señales de medición aquellas componentes producidas por la red eléctrica, dejando únicamente las componentes útiles para el diagnóstico de fallas, para su aplicación, evalúa el diseño de filtros en el dominio de la frecuencia (tipo comb) y de procesamiento en el dominio temporal (técnicas multirate). Villalobos (2015) presentó un conjunto de herramientas basadas en la transformada rápida de Fourier (TRF) y la transformada discreta ondeleta (TDO) Haar, Daubechies y Coiflet utilizando el módulo del vector espacial instantáneo (VEI) de las corrientes del estator del motor de inducción trifásico para diagnosticar las fallas. Otro de los trabajos encontrados que se relacionan con los sensores inteligentes para la detección en línea de fallas en motores, es

el de Garcia-Ramirez et al (2012), quienes crean un sensor inteligente para la detección en línea de múltiples fallas combinadas en motores de inducción alimentados a través de un VSD en un amplio rango de frecuencia, basado en un sensor primario de efecto Hall, utilizando una metodología basada en la transformada rápida de Fourier (FFT), el cálculo de RMS y las redes neuronales artificiales (ANN).

Al hacer la revisión de la bibliografía se ha visto una gran importancia de estudio sobre las máquinas electromecánicas rotatorias por el gran uso que se tiene sobre ellas, por otro lado como se vio en las estadísticas la mayor parte de fallas en estas máquinas las proporcionan los rodamientos, también se pudo analizar que la primer etapa de falla en los baleros o cojinetes se dice que comienzan con vibraciones de alta frecuencia, por las ondas de esfuerzo producidas, lo que se puede aprovechar para hacer el análisis de la detección de falla antes que proceda a las siguientes etapas de falla, provocando un daño mayor a la máquina electromecánica rotativa. Debido a que en la industria necesita un análisis constante sobre el estado de su maquinaria, se ha pensado en realizar un sensor inteligente que detecte dichas fallas en rodamientos tanto metálicos como cerámicos, por medio de la adquisición de datos de vibraciones, teniendo un procesamiento necesariamente en línea e implementando las técnicas de tiempo-frecuencia, por las ventajas complementarias ya mencionadas que estas ofrecen a la hora de analizarse de manera conjunta.

## **1.2 DESCRIPCIÓN DEL PROBLEMA**

- Después de haber revisado los trabajos, se detectó que el motor de inducción es la máquina eléctrica más utilizada en el sector industrial a nivel mundial, y que la detección de sus fallas tempranas es uno de los problemas más significativos, no obstante, la probabilidad de que el motor de inducción se dañe de los rodamientos es del 69% en comparación con otras varias fallas, ya que es la parte del motor que se encuentra en constante movimiento.
- Los rodamientos cerámicos tienen mejores propiedades que los rodamientos metálicos por lo que algunas industrias han optado por remplazarlos, aunque estos

tengan un costo superior. Sin embargo, no se encontraron trabajos de detección de fallas tempranas en rodamientos cerámicos en motores de inducción, tampoco se encontraron trabajos donde se realice una comparativa de rodamientos metálicos y rodamientos cerámicos donde se describa si las técnicas utilizadas para la detección de fallas en rodamientos metálicos puedan ser útil para la detección de fallas en los rodamientos cerámicos.

- Se ha descubierto mucha información con técnicas de tiempo o técnicas de frecuencia, pero existe muy poca que hable de las técnicas de tiempo-frecuencia y más aún aplicada a detección de fallas en rodamientos cerámicos y metálicos.
- No existe el desarrollo completo de sensores inteligentes que realicen la detección de fallas tempranas en rodamientos cerámicos.
- No se encontraron trabajos de detección de fallas en baleros metálicos y cerámicos mediante un sensor inteligente que involucre la implementación de técnicas de tiempo-frecuencia y además sean capaces de realizar el procesamiento en línea.

### **1.3 JUSTIFICACIÓN**

- Debido a que existe un alto índice de probabilidad por la aparición repentina de fallos incipientes en la mayoría de maquinaria industrial que usa rodamientos, es necesario contar con información fiable extraída de magnitudes físicas para realizar la detección de fallas en una etapa temprana y así aplicar acciones de mantenimiento preventivo y no correctivo para reducir costos en la reparación.
- Dado el hecho que las magnitudes físicas proporcionan información importante de aplicaciones en el mundo real, es necesario procesarlas para extraer información relevante. En este sentido, las técnicas de tiempo proporcionan ciertas características que no se pueden obtener con las técnicas de frecuencia y viceversa; y ante esta

situación, se requiere realizar la implementación de técnicas de análisis del dominio tiempo-frecuencia para mejorar el análisis de manera conjunta.

- Se desarrollará un sensor inteligente que por medio de la adquisición y procesamiento de datos de vibraciones y corrientes detecte a tiempo las fallas en rodamientos metálicos y cerámicos.
- Además, en la actualidad se carece de sensores inteligentes, que basados en la adquisición y procesamiento en línea de señales con técnicas del dominio tiempo-frecuencia, realicen acciones de monitoreo y diagnóstico automático.

#### **1.4 HIPÓTESIS**

Mediante la implementación de técnicas de tiempo-frecuencia y su ejecución en un procesador, será posible hacer el monitoreo y detección de fallas en rodamientos metálicos y cerámicos, mejorando así el tiempo de detección de fallas en los sistemas electromecánicos.

#### **1.5 OBJETIVOS**

##### **Objetivo General**

Desarrollar un sensor inteligente para detección de fallas en cojinetes metálicos y cerámicos, mediante la implementación de técnicas de tiempo-frecuencia y su ejecución en un procesador.

##### **Objetivos Particulares**

1. Experimentar y analizar las diferentes condiciones de fallo de rodamientos metálicos y cerámicos en un motor mediante las técnicas de procesamiento de señales y extraer las adecuadas para la detección de fallas.

2. Fabricar las fallas en los rodamientos y adquirir las bases de datos para la identificación de fallos en motores de inducción mediante las técnicas de procesamiento de señales.
3. Programar y simular en software las técnicas adecuadas elegidas para la localización de fallas en rodamientos metálicos y cerámicos.
4. Analizar la efectividad ofrecida por técnicas de análisis basadas en el dominio tiempo-frecuencia para la caracterización de fallos producidos en motores de inducción por rodamientos cerámicos.
5. Desarrollar las técnicas de tiempo-frecuencia seleccionadas para la percepción de fallas en cojinetes metálicos y cerámicos, mediante un lenguaje de programación y su correspondiente simulación.
6. Aplicar técnicas de análisis de señales en el dominio tiempo-frecuencia y de técnicas para la reducción de la dimensionalidad basadas en el Análisis de Componentes Principales (PCA) y Análisis Discriminante Linear (LDA), aplicadas en esquemas de condición de monitoreo y diagnóstico de fallos.
7. Aplicar el análisis de una base de datos de diferentes pruebas experimentales bajo diferentes condiciones de trabajo para la validación de una metodología de condición de monitoreo propuesta.
8. Analizar y desarrollar técnicas de clasificación, aplicadas en la identificación de diferentes condiciones de operación en motores de inducción.
9. Implementar en un procesador la integración de un sensor inteligente y su aplicación en la detección en línea de fallas en rodamientos sobre un motor.

# CAPÍTULO II

## 2. FUNDAMENTACIÓN TEÓRICA

En este capítulo se da a conocer los diferentes aspectos teóricos necesarios que facilitaron el desarrollo del sensor inteligente basado en técnicas de tiempo-frecuencia para la detección de fallas de rodamientos metálicos y cerámicos en motores de inducción, así como también la información necesaria para el procesamiento de señales fuera de línea.

### 2.1 INTRODUCCIÓN

A lo largo de la historia, han sucedido diferentes acontecimientos que han permitido ver cómo afecta la evolución de la industria al resto de la sociedad. La Revolución Industrial nació en Gran Bretaña y se extendió luego al resto de Europa, fue entre los siglos XVIII y XIX, donde se mecanizaron los procesos de producción que solían ser manuales, esto transformó la economía agraria y artesanal en otra liderada por la industria, entre los inventos más comunes introducidos en esa época fueron la máquina de vapor, como el ferrocarril que utilizaba el carbón como fuente de energía, el primer telar mecánico, el telégrafo y el teléfono también revolucionaron la forma en que las comunicaciones eran concebidas en ese momento. Debido al rápido avance de producción que se dio en esta revolución, se comenzó a buscar formas de producir más rápido y mejorar la calidad, por lo que nació la división de tareas que constituye a la Segunda Revolución Industrial, esta se lleva a cabo en el siglo XX, donde se dio la producción en serie con la aparición de fábricas y líneas de montaje que permitieron fabricar productos para un gran consumo, los sistemas mecánicos de tracción hidráulicos y de vapor dieron paso a los sistemas eléctricos esto con ayuda de la energía eléctrica, todo esto permitió el desarrollo de las industrias química, eléctrica y automovilística por lo que el coche y, más tarde el avión, nacieron al albor de los cambios que supuso este segundo periodo, estos últimos medios cambiaron el carbón por el petróleo

como su fuente de energía. La Tercera Revolución Industrial se dio a finales del siglo XX, donde el despliegue de la electrónica, la tecnología de la información y las telecomunicaciones en los procesos industriales dio paso al proceso de automatizar las líneas de producción y que las máquinas comenzarán a remplazar a las personas en tareas que eran muy repetitivas, dos décadas de grandes avances en la tecnología del internet produjeron una importante innovación en el modo de ver y entender la vida y sobre todo la comunicación, las energías alternativas y renovables, la nuclear y el petróleo se ha establecido durante estos años como principales fuentes para el consumo diario en los medios de transporte, en este sentido, los inventos más importantes fue el tren de alta velocidad y los vehículos eléctricos o biocarburos. Pese a que la mayoría de los avances e innovaciones mencionados siguen vigentes hoy en día, el uso que se hacen de los mismos si ha cambiado, como la aplicación de las tecnologías como la inteligencia artificial, la fabricación aditiva, la realidad aumentada o el internet de las cosas (IoT), son unas de las tecnologías centrales que está impulsando la Cuarta Revolución Industrial, esta se conoce como Industria 4.0, que junto con el enorme avance que han tenido las otras tecnologías de fábrica (OT, Tecnologías de Operación: controladores, robótica, comunicaciones industriales, informática industrial, etc.) y de empresa (IT, Tecnologías de Información: sensores inteligentes y en red, IoT, digitalización y análisis de Big Data, seguridad, etc.) están produciendo un cambio radical en la industria permitiendo un avance hacia la fabricación personalizada y colaborativa, desde el prediseño hasta la entrega del producto. esta se basa en la transformación ciber-física de los procesos, sistemas y métodos de fabricación, y en su operación autónoma y descentralizada, aunque coordinada con los sistemas comerciales y logísticos (Bernal,1979). Por lo tanto, digitalizando e interconectado el entorno industrial es posible desarrollar una virtualización de la fábrica y sus procesos para la mejora de los indicadores de la producción y de la eficiencia energética relacionada, así como también, tener un buen control de la misma disminuyendo las fallas y por ende el mantenimiento correctivo que conlleva a pérdidas monetarias significativas y demoras en la fabricación o tratamiento del producto final. Es por ello, que se propone un sensor inteligente, donde dicho dispositivo entraría en el diagnóstico de la maquinaria, es decir, detectar la falla antes de que el mecanismo entre a un estado catastrófico.

## 2.2 MOTORES DE INDUCCIÓN (MI)

Hablar de fallas electromecánicas conlleva a extender demasiado la investigación ya que es una rama muy amplia que no solo hace referencia a lo industrial si no a cualquier falla que contenga movimiento inducido por electricidad o viceversa. Esta tesis está enfocada al sector industrial, ya que después de la revisión de los antecedentes, se percató que en dicha rama se cuenta con un mecanismo ampliamente importante por contener el 90% del consumo eléctrico a nivel mundial (Figura 1), se trata del motor de inducción, que a su vez el 60% de los motores que existen son de ese tipo.



Figura 1. a) Consumo eléctrico mundial. b) Uso de MI (Autoría propia)

Estas son las razones más importantes que lleva a la decisión de enfocar este estudio a los motores de inducción, pero a todo esto, como se define o distingue un motor de inducción a comparación con otros motores, y que es lo que lo hace situarse en el más utilizado en el mundo. En respuesta se tiene que el motor de inducción fue inventado por separado en 1885 por Galileo Ferraris y en 1887 por Nikola Tesla, posteriormente en 1890, Mikhail Dolivo-Dobrovolsky invento el motor de inducción con rotor de jaula de ardilla. El motor de inducción es una máquina eléctrica que se denomina también máquina asíncrona, ya que la velocidad de rotación del rotor no es igual a la velocidad síncrona, su funcionamiento está basado en la interacción de campos magnéticos producido por las corrientes eléctricas. Las corrientes que circulan por el rotor son producidas por inducción electromagnética, comúnmente conocida como ley de Faraday. Esta ley establece que si una espira es atravesada por un campo magnético variable en el tiempo se tiene entre sus extremos una diferencia de potencial dado por la ecuación (1).

$$e = -\frac{d\Phi}{dt} \quad (1)$$

Donde:

$e$  = diferencia de potencial inducida en la espira en voltios

$\Phi$  = flujo que corta la espira en Weber

$t$  = tiempo en segundos

El signo negativo está determinado por la expresión de la ley de Lenz. La cual establece que la polaridad del voltaje inducido en la bobina es tal que, si sus extremos se pusieran en cortocircuito, produciría una corriente que causaría un flujo para oponerse al cambio de flujo original. Puesto que el voltaje inducido se opone al cambio que lo causa, se incluye el signo menos en la ecuación (1).

Si se distribuye espacialmente alrededor del estator de un motor los bobinados de un sistema de tensiones trifásicos desfasadas  $120^\circ$  se genera un campo magnético giratorio. La velocidad de giro de este campo magnético, denominada velocidad de sincronismo, viene dada por la ecuación (2).

$$n = \frac{60 * f}{p} \quad (2)$$

Donde:

$n$  = Velocidad de giro del campo magnético en r.p.m.

$f$  = Frecuencia de la corriente eléctrica de alimentación de la máquina

$p$  = Número de pares de polos magnéticos establecidos en el bobinado del estator

De este modo se tiene que las velocidades de sincronismo (Tabla 1) de las máquinas eléctricas en función del número de polos para una frecuencia eléctrica fija en 50Hz son:

**Tabla 1. RPM de un MI según sus números de pares de polos**

Numero de pares de polos	r.p.m. del campo magnético
$p = 2$	$n = 3000$ r.p.m.
$p = 4$	$n = 1500$ r.p.m.
$p = 6$	$n = 1000$ r.p.m.

Por lo tanto, en estos motores la velocidad de giro del rotor es inferior a la velocidad de giro del campo magnético, esto se debe a la fricción en los cojinetes del rotor, rozamiento con el aire y a la carga que contiene el eje del rotor. A esta diferencia de velocidades se le conoce como deslizamiento, generalmente se expresa en tanto por ciento y se presentan dos tipos (Tabla 2).

**Tabla 2. Diferencia de velocidades**

Deslizamiento absoluto	Deslizamiento relativo
$s = n1 - n2$	$s\% = \frac{n1 - n2}{n1} * 100$

Donde:

$s$  = deslizamiento

$n1$  = velocidad de sincronismo

$n2$  = velocidad de giro del rotor

Entonces, la frecuencia a la que están sometidos los conductores del rotor es:

$$fr = s * f \quad (3)$$

Donde:

$f$  = frecuencia en Hz de la red eléctrica de alimentación del motor

La mayor ventaja de los motores de inducción de corriente alterna es su simplicidad. Solo tienen una parte móvil, el rotor, que los hace de bajo costo, silenciosos, de larga duración y relativamente libres de problemas, fácil mantenimiento y versatilidad. Los motores de corriente continua, por el contrario, tienen un conmutador y escobillas de carbón que se desgastan y deben reemplazarse de vez en cuando. La fricción entre los cepillos y el conmutador también hace que los motores de corriente directa sean relativamente ruidosos.

Básicamente el motor de inducción está conformado de tres partes fundamentales, que son el rotor, estator y la carcasa, sin embargo, también cuenta con algunos otros componentes importantes. En la Figura 2 se muestran todas las partes que componen a un motor de inducción de jaula de ardilla.

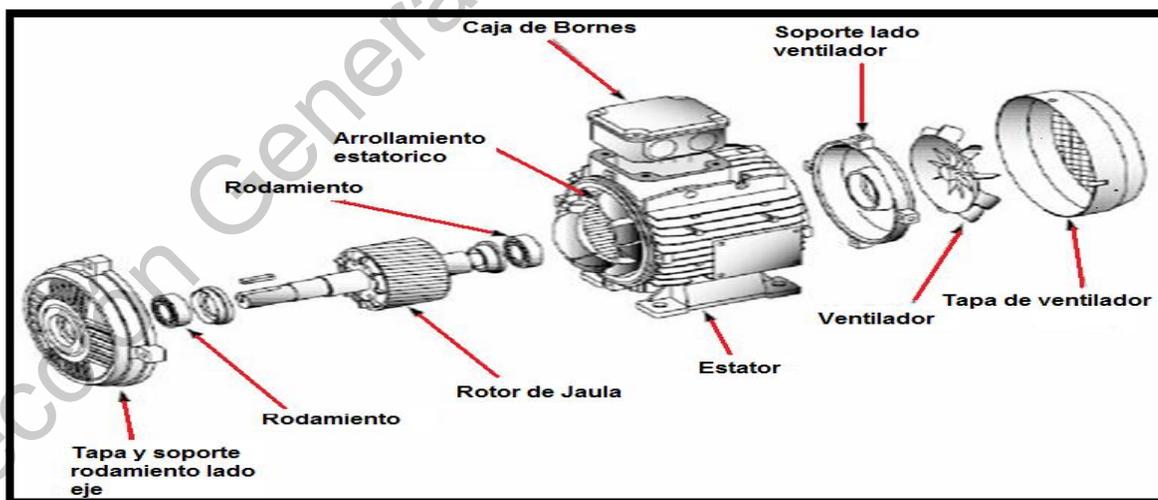


Figura 2. Partes de un motor de inducción (MI)

La placa de características de un motor trifásico como se muestra en la Figura 3, da el valor máximo de la tensión a que se puede conectar el motor a la red eléctrica. Un motor

conectado en estrella ( $\gamma$ ) como se muestra en los bornes de la figura, soporta la tensión más alta que indica la placa, en tanto que en conexión de triángulo ( $\Delta$ ) la tensión máxima a que se puede conectar es la más baja indicada en dicha placa de características. Con las corrientes absorbidas ocurre justo lo contrario, correspondiendo la corriente más alta a la conexión triángulo ( $\Delta$ ).

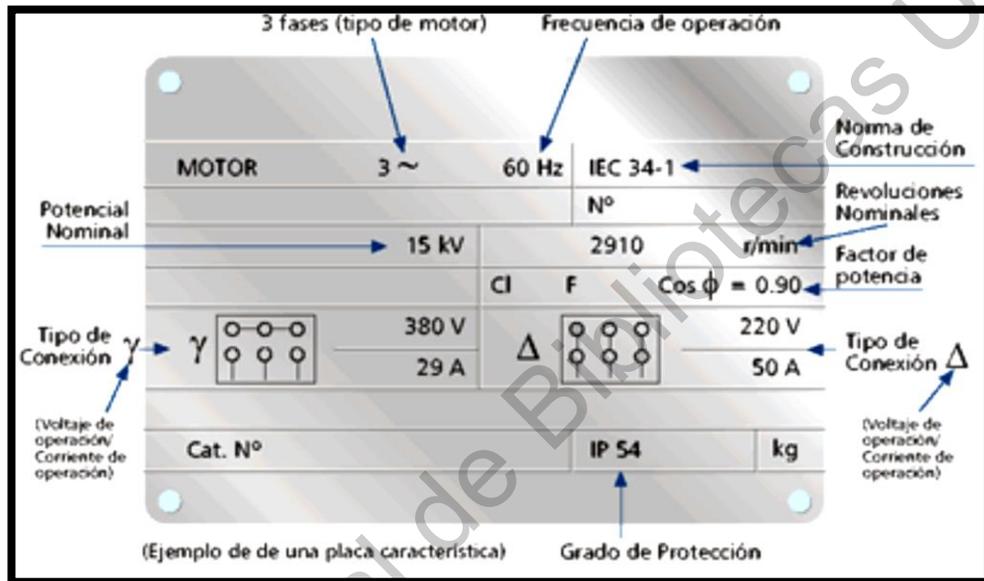


Figura 3. Placa característica de un motor trifásico

### Fallas en motores de inducción

La clasificación de fallas en motores de inducción puede estar dividida en tres grupos:

- Fallas mecánicas
- Fallas eléctricas
- Fallas de enlace de potencia

Por el enfoque que tiene esta investigación, solo se revisará el grupo de fallas mecánicas, ya que los rodamientos se ven sumamente afectados en cualquier falla que entre en este apartado por el impacto en la vibración que pueden generar.

## Desalineamiento

El desalineamiento se define como la condición en que los ejes de la máquina conductora y conducida no poseen la misma línea de centros. Siempre va existir una pequeña desalienación, la alineación perfecta no existe, por ende, es de suma importancia escoger un acoplamiento que logre absorber dicho defecto con el fin de minimizar los esfuerzos generados. En la realidad siempre existe un desalineamiento combinado, con lo cual hace referencia al hecho que existe dos tipos de desalineamiento:

**La angular:** El desalineamiento angular se muestra en la siguiente Figura 4 donde dos líneas centrales al eje tienen un ángulo una respecto de otra, puede ocurrir horizontal o verticalmente.

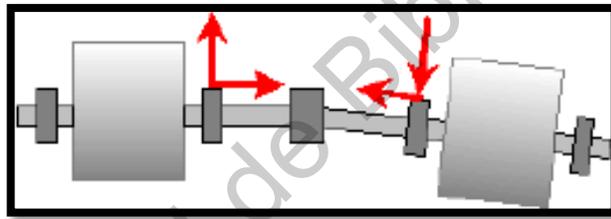


Figura 4. Desalineamiento angular

**La paralela:** El desalineamiento paralelo se muestra en la siguiente Figura 5, donde las líneas centrales de la flecha se encuentran paralelamente perfectas, pero están desfasadas una de otra.

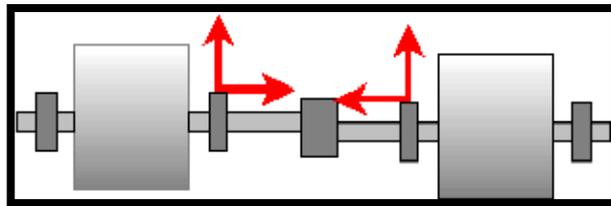


Figura 5. Desalineamiento paralelo

## Desbalance

El desbalance mecánico es la fuerza que se crea en una pieza, cuando su eje inercial se encuentra desplazado del eje geométrico de rotación, originado por causas como el

desgaste de partes, la deformación del material, el desprendimiento de partes, el mal ensamble de componentes, golpes, entre otros. Es una de las causas más comunes que producen vibraciones, los componentes sufren incrementos en los niveles de amplitud a causa de la velocidad, unos experimentan bajos niveles de vibración, mientras que otros padecen elevados niveles de vibración radial pero bajísimos niveles de vibración en la dirección axial. el desbalance produce oscilaciones importantes en el par instantáneo requerido por el motor, produciendo fatiga de los elementos de transmisión tales como correas, poleas, chavetas, rodamientos y ruedas dentadas.

Los problemas que pueden producir desbalance son:

- Aglomeración desigual de polvo en los alabes de un ventilador
- Falta de homogeneidad en partes coladas, como burbujas, agujeros de soplado y partes porosas
- Excentricidad del rotor
- Flexión de rodillos, especialmente en máquinas de papel
- Defectos constructivos
- Distribución desigual en las barras del rotor de motores eléctricos o en el enrollado
- Erosión y corrosión desigual de las impulsoras de una bomba
- Pesos de balanceo que faltan
- Flecha con flexión

El desbalance de un motor puede ser de tres tipos:

- Desbalance estático
- Desbalance en dos planos o tipo par
- Desbalance por rotor colgante

## Excentricidad

La excentricidad es otra causa común de vibración en una máquina rotativa. Se produce cuando la línea central del eje no es la misma que la línea central del rotor, el centro de rotación verdadero difiere de la línea central geométrica.

Tipos de excentricidades:

- Excentricidad de tipo estática
- Excentricidad de tipo dinámica
- Excentricidad combinada estática-dinámica

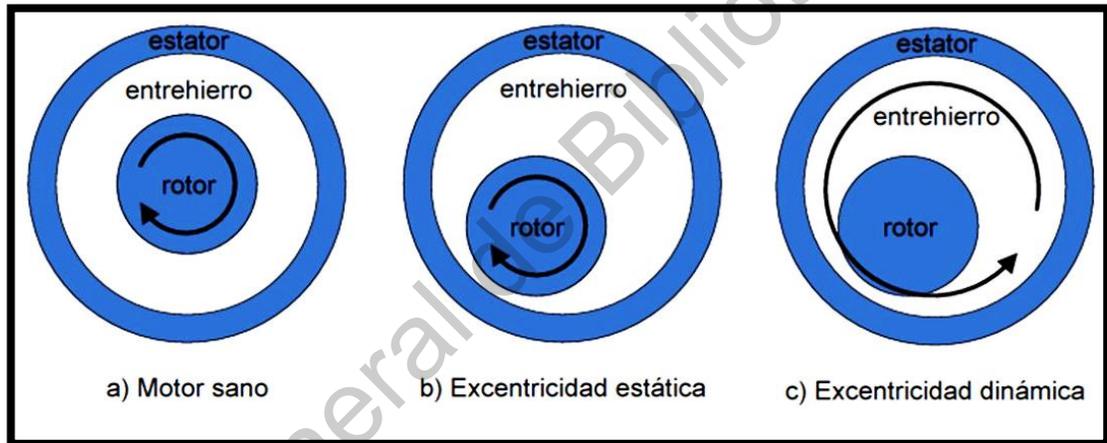


Figura 6. Tipos de excentricidad

La excentricidad puede causar daños en el motor debido al golpeteo entre el rotor y el estator, así como frecuencias inducidas por la combinación de excentricidades estática y dinámica en la corriente de alimentación de un motor de inducción.

## Rodamientos

Los rodamientos son mecanismos que facilitan el movimiento relativo entre dos componentes de una máquina, generalmente empleados para orientar y minimizar la fricción de un eje en una máquina rotativa. Las aplicaciones de los rodamientos son muy variadas, estos se pueden encontrar en diferentes tipos de motores eléctricos, turbinas, taladros, entre

otros. Los rodamientos están entre los más importantes y frecuentemente encontrados componentes en la gran mayoría de las máquinas rotativas, su capacidad de carga y confiabilidad son vitales para el adecuado desempeño de la máquina. Los rodamientos están conformados como se muestra en la Figura 7.

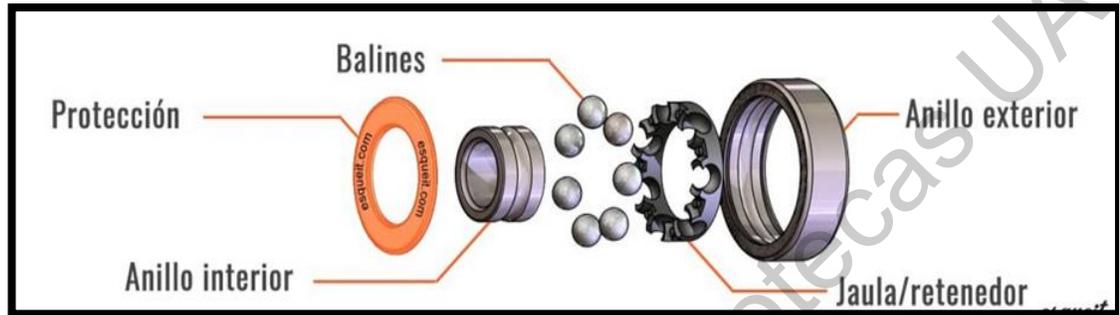


Figura 7. Partes de un rodamiento.

La detección y diagnóstico de fallas en etapas prematuras de daño, son necesarias para evitar su mal funcionamiento y fallos durante su operación. Cuando una falla localizada en una superficie de rodamiento choca con otra superficie, se generan componentes de vibración no síncronos. La existencia de componentes no síncronos en un espectro de vibraciones es el indicador más claro de problemas en los rodamientos y permite excluir otras posibles fuentes que originan la vibración.

Las fallas en los rodamientos son las más comunes en los motores, se manifiestan por vibraciones de alta frecuencia un ejemplo se muestra en la Figura 8, una vez detectada la falla el rodamiento debe ser remplazado, debido a que la falla seguirá incrementándose.

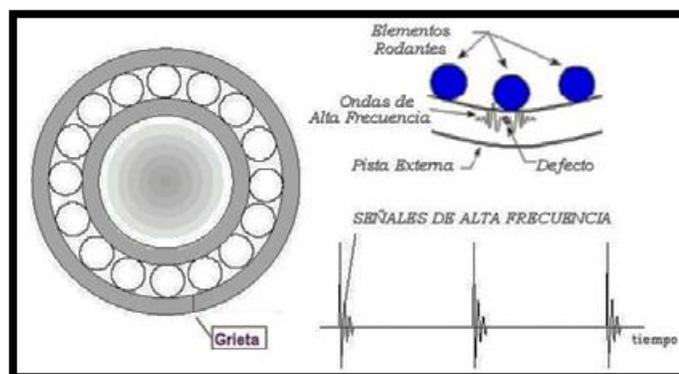


Figura 8. Ejemplo de frecuencia de falla en un rodamiento

Las causas más comunes son:

- Carga excesiva
- Falta de alineamiento
- Defectos de asientos del eje y/o de las perforaciones en el alojamiento
- Montaje defectuoso
- Ajuste incorrecto
- Lubricación inadecuada o incorrecta
- Sellado deficiente
- Deformación bajo carga

El comportamiento general del rodamiento está determinado por la interacción entre sus elementos. Los contactos entre los elementos de rodamiento y las pistas o cajas son los sometidos a mayores cargas, de ahí que los fallos por fatiga estén principalmente motivados por esta interacción. Los contactos entre elementos de rodamiento y caja y los contactos entre pistas y caja son generalmente de naturaleza dinámica ya que constituyen una serie de choques de corta duración y alta velocidad. La Tabla 1 muestra las frecuencias características debido a los siguientes defectos:

Tabla 3. Frecuencias características de fallas en rodamientos de bola

Frecuencia debida a defectos en la pista externa	$f_{outer} = \left(\frac{N_b}{2}\right) f_r \left[1 - \frac{D_b \cos(\beta)}{D_c}\right]$
Frecuencia debida a defectos en la pista interna	$f_{inner} = \left(\frac{N_b}{2}\right) f_r \left[1 + \frac{D_b \cos(\beta)}{D_c}\right]$
Frecuencia debida a defectos en las bolas	$f_{ball} = \left(\frac{D_c}{2D_b}\right) f_r \left[1 - \left(\frac{D_b \cos(\beta)}{D_c}\right)^2\right]$
Frecuencia debida a defectos de jaula	$f_{cage} = \left(\frac{f_r}{2}\right) \left[1 - \frac{D_b \cos(\beta)}{D_c}\right]$

Donde:

$N_b$  = el número de bolas

$D_b$  = Diámetro de bola

$D_c$  = diámetro de paso

$\beta$  = ángulo de contacto

$f_r$  = velocidad del eje en revoluciones por segundo

### **Rodamientos cerámicos**

El compuesto cerámico que se suele utilizar para la fabricación de los sistemas de rodamientos es nitruro de silicio ( $\text{Si}_3\text{N}_4$ ). La alta velocidad, alta rigidez y alta fiabilidad se consiguen con los elementos rodantes cerámicos. Ofrecen muchas y excelentes prestaciones como la resistencia a la temperatura, la disminución de la masa rodante, la menor dilación térmica y la baja conductibilidad eléctrica gracias a las cuales se pueden ensamblar en un gran número de aplicaciones como una nueva generación de materiales, otra de las grandes ventajas de los rodamientos es la imposibilidad de que se produzcan fenómenos corrosivos y además no es necesario en la mayoría de los casos el tener que lubricar. Por las características de dureza que la cerámica proporciona siempre estos mecanismos se hacen absolutamente silenciosos sin importar la velocidad a la que se haga funcionar el sistema. La vida útil también será muy larga ya que el desgaste térmico y el mecánico es prácticamente nulo.

La Figura 9 muestra un rodamiento completamente cerámico, y dos híbridos (compuesto por partes metálicas y partes cerámicas).



Figura 9. Rodamientos cerámicos e híbridos

Cuando se tiene una variante mixta igualmente existen ventajas frente a un rodamiento de acero. Únicamente sustituyendo las bolas de acero por las cerámicas se ahorra un peso del 40%. Una eliminación del peso implica reducir la carga centrífuga de un modo muy significativo y ello conlleva que aplicando el mismo esfuerzo mecánico el rendimiento se mejora alrededor del 30%. Las bolas cerámicas girarán a mayor velocidad con menor desgaste y fricción sobre las bandas de rodamiento dando mejores prestaciones. Otra de las cualidades que aportan las bolas hechas a base de compuestos cerámicos es la eliminación de molestos efectos que puede generar un sistema que no es eléctricamente inerte. Otra ventaja de este tipo de bolas es que hay ciertos tipos de situaciones en los que los lubricantes no pueden ser usados, por ejemplo, en el espacio. Este es el terreno adecuado para la cerámica pues no necesita de aceites ni grasas.

Más particularidades:

- **Baja Masa**

Debido que la densidad es un 40% inferior a la del acero, la fuerza centrífuga de los elementos rodantes es menor, ampliando de esta forma la vida de los rodamientos.

- **Bajo Coeficiente de Dilatación Lineal**

En las aplicaciones con un funcionamiento a alta velocidad, aunque la temperatura del rodamiento sea elevada, su bajo coeficiente de dilatación lineal dará como resultado una precarga inferior y una menor generación de calor.

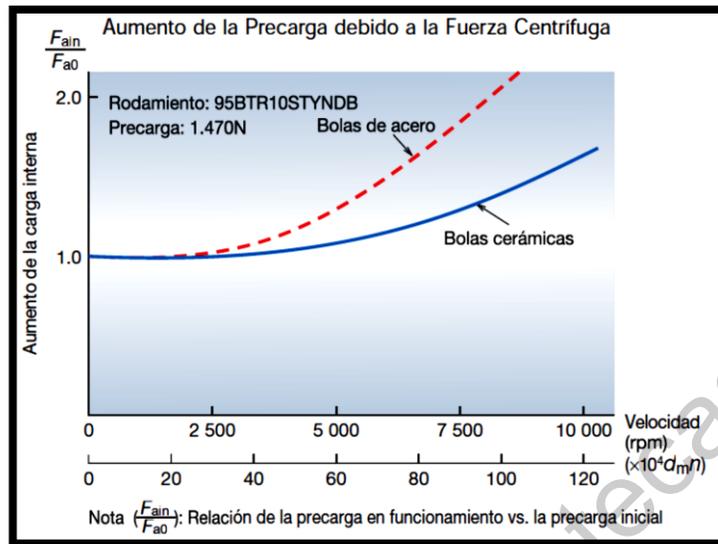


Figura 10. Comparación de dilatación lineal

- **Baja Fricción**

Durante el funcionamiento, se reduce el deslizamiento del elemento rodante, dando como resultado una menor generación de temperatura.

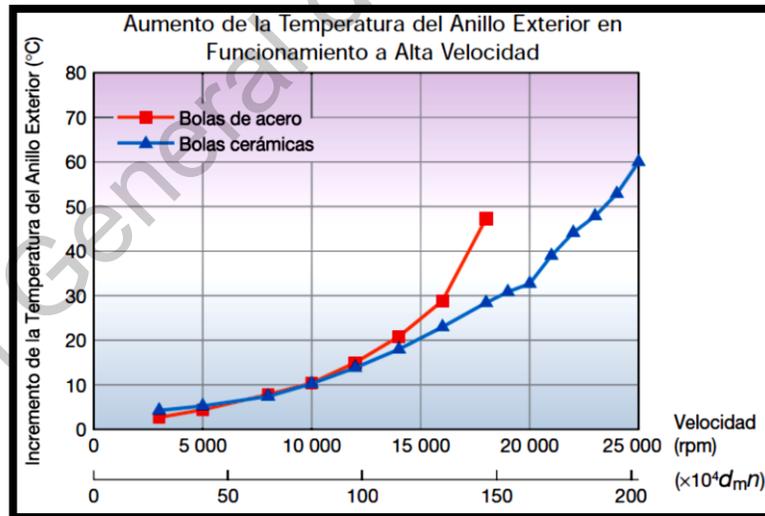


Figura 11. Comparación de temperatura

- **Resistencia al Desgaste de Deslizamiento**

Con relación a los elementos rodantes de acero, los elementos cerámicos ofrecen una mayor resistencia al desgaste de deslizamiento.

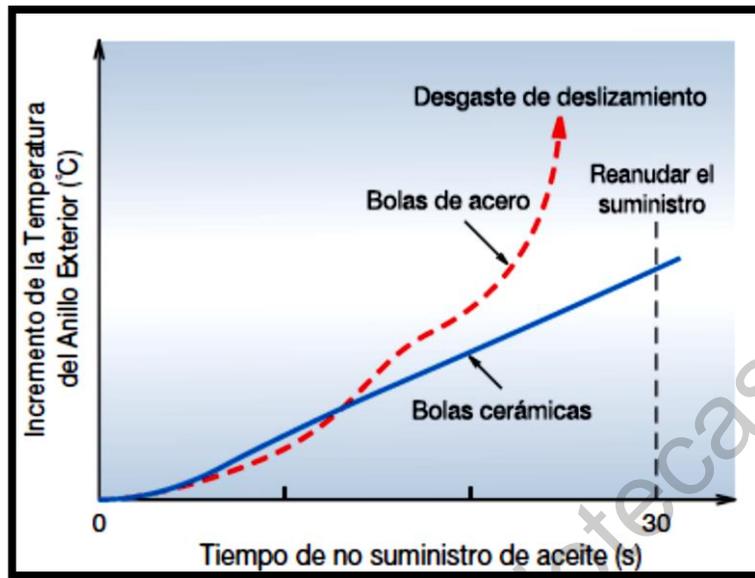


Figura 12. Comparación de desgaste

- **Alta Rigidez**

Las bolas cerámicas tienen un módulo de Young un 50% superior al del acero, lo que las convierte en un material idóneo para utilizar en husillos de máquinas-herramienta que requieren una elevada rigidez durante el proceso de corte.

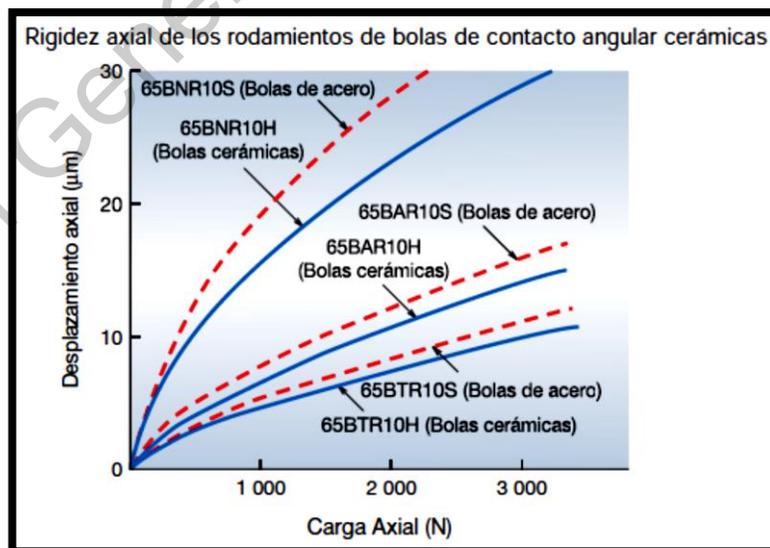


Figura 13. Comparación de rigidez axial

## 2.3 ADQUISICIÓN DE SEÑALES

Cuando se habla de un sistema de adquisición de datos, se pueden identificar cuatro partes o elementos principales: hardware, software, computadora personal (PC) y sensores. Las características y funciones de cada uno de estos elementos determinan en gran parte el adecuado desempeño del sistema. Por ejemplo, la PC debe contar con un procesador o suficiente memoria de acceso aleatorio (RAM) para poder transferir y procesar continuamente todos los datos adquiridos, de lo contrario la velocidad máxima de lectura se eliminará.

### Sensores

Los sensores son elementos que comúnmente son utilizados para realizar la medición de magnitudes físicas como vibración, sonido, luz, humedad, temperaturas, etc. En este sentido, a través de la medición de variables físicas se puede dar una interpretación del estado actual de una maquinaria en operación, esto se puede realizar debido a que la mayoría de sensores están en contacto directo con la maquinaria que se encuentre bajo monitoreo; y consecuencia, cualquier cambio repentino que afecte la condición de operación puede ser detectado gracias a la modificación del comportamiento de la magnitud física que se esté midiendo.

Por ejemplo, en la mayoría de máquinas rotatorias comúnmente suelen presentarse condiciones de Desalineamiento; por lo tanto, si se habla que para la condición sana de la máquina los niveles de vibración generados son relativamente nulos, ante la aparición de condiciones de operación de desbalance los niveles de vibración que comúnmente se experimentan en la máquina tenderán a incrementarse. Para este caso particular, será suficiente con emplear un sensor que sea capaz de realizar mediciones de vibración para poder dar una interpretación de la condición de estado de la maquinaria.

Además, cabe mencionar que la correcta instrumentación de sensores juega un papel importante para realizar una correcta la medición de diferentes variables físicas; en casos particulares las etapas de amplificación o de acondicionamiento son muy rigurosas para

posteriormente garantizar la lectura apropiada de las diferentes magnitudes físicas.

### **Características de los sensores**

Existen diferentes aspectos que deben considerarse durante el diseño y desarrollo de sistemas de adquisición de datos (Data Acquisition System-DAS), enseguida se enlistar algunos de los puntos más relevantes:

- La naturaleza de la señal generada por el sensor, se debe tener completo conocimiento de señal generada durante la medición de una variable física debido a que un sensor puede generar señales de voltaje, frecuencias, amplitud, etc.
- La influencia de ruido de las señales (Signal to noise ratio-SNR)
- La calibración del sensor respecto a otros dispositivos para asegurar que las lecturas obtenidas por el sensor pertenezcan a lecturas reales de la magnitud física cuantificada.
- La interdependencia entre diferentes elementos empleados en la DAS, esto significa que se deben de emplear elementos con índices de funcionalidad similares.
- La precisión del sensor será importante ya que garantizará la repetitividad de la misma medición en diferentes ocasiones.
- El tiempo de respuesta es significativo debido a que se debe de tener la capacidad de hacer la medición ante cambios repentinos y bruscos sobre las variables físicas.
- El coeficiente de temperatura debe ser considerado por las modificaciones que puedan generar un sensor sobre la lectura de una magnitud física.

- La histéresis, es un efecto que tiene efectos sobre la dependencia de salida de los sensores respecto a respuestas anteriores.

Por otra parte, existen diferentes formas de clasificación de sensores, una primera clasificación se puede hacer basándose en su principio de funcionamiento; los sensores inductivos, capacitivos y resistivos son de los más conocidos. Una segunda clasificación puede depender del tipo de variable física que el sensor es capaz de medir y finalmente también se puede hacer una clasificación dependiendo de si el sensor tiene la capacidad por generar energía, o de si necesitan de un circuito auxiliar para generar su respuesta, (Creus,2010).

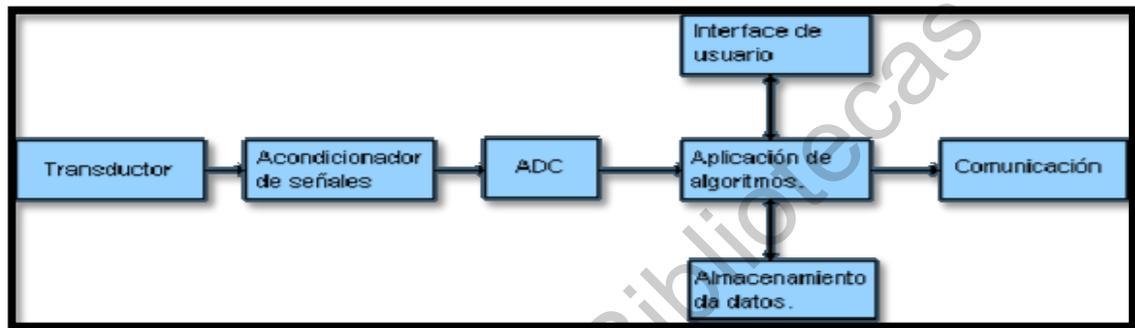
### **Sensores inteligentes**

Existen varias definiciones de sensores inteligentes. De forma general se puede decir que un sensor inteligente es un equipo en el cual uno o más elementos sensores y algún acondicionamiento de señal son integrados en la misma pastilla de silicio o forman un pequeño sistema miniaturizado. Cuando inclusive se integra al microcontrolador se dicen “sensores inteligentes integrados”. Un sensor inteligente es aquel que combina la función de detección y alguna de las funciones de procesamiento de la señal y comunicación.

Por otra parte, según el IEEE 1451.2 un transductor inteligente es aquel que proporciona más funciones de las necesarias para generar una correcta representación de la variable monitorizada, dichas funcionalidades típicamente están orientadas a facilitar la integración del transductor con las aplicaciones del entorno de red. La definición que se aporta para el término Sensor Inteligente es: “La versión en sensor de un transductor inteligente”. Se desprende pues que un sensor inteligente añade valor a los datos para dar soporte a la toma de decisiones y al procesamiento distribuido. Los ambientes inteligentes representan el nuevo paso en la evolución en la automatización de los sistemas industriales, domésticos, de transporte y de la construcción.

Al igual que un organismo sensitivo, un entorno inteligente confía en los datos sensoriales obtenidos del mundo real. Los datos sensoriales provienen de múltiples sensores,

de múltiples propósitos distribuidos por múltiples localizaciones. Los ambientes inteligentes necesitan tanto la información del entorno que les rodea como la información de su propio funcionamiento. A continuación, se observa de el diagrama general de un sensor inteligente en la Figura 14, un sensor inteligente se caracteriza por su potencia de cálculo y procesamiento descentralizado que permite el procesamiento de información digital y la comunicación con la red de información.



**Figura 14. Diagrama de un sensor inteligente**

Las funciones características más comunes que hacen que las herramientas de medición de los sensores inteligentes de nueva generación son:

- El cálculo directo del valor de medición recibido ajustado por los factores de confusión, sin tener que recurrir a la calibración de la computadora central.
- Las señales suministradas son digitales en vez de analógicos.
- Capacidad para identificar el sensor.
- La comunicación con el ordenador central de la red en lugar de sólo el envío.
- Incluir las mejoras adicionales en el transmisor, liberando a la computadora central de las tareas secundarias.
- Capacidad para realizar el autodiagnóstico y la elaboración de directrices para el

desarrollo futuro.

- Capacidad para compensar en sistemas de tiempo real para la medición y la recepción de datos y los sistemas de control en un ciclo cerrado.
- Posibilidad de multi-sensores.

### **Acondicionador de señal**

El objetivo del acondicionador de señal es generar, a partir de lo obtenido por los sensores, una señal que sea aceptable por las tarjetas de adquisición de datos. Las tarjetas de adquisición de datos suelen admitir niveles de tensión que van entre unos márgenes determinados: -10V a 10V, 0 a 10V, 0 a 5V, etc.

Las funciones principales que va a tener que realizar el acondicionador de señal son las siguientes:

- **Transformación:** Los sensores pueden proporcionar una diferencia de potencial, o una variable de intensidad. Normalmente las tarjetas de adquisición de datos admiten diferencias de potencial, por lo que, si el sensor proporciona una variación de intensidad, esta debe ser convertida en una diferencia de potencial proporcional.
- **Amplificación:** La señal proporcionada por los sensores suele ser de un valor muy pequeño, por lo que debe ser amplificada con el fin de que pueda ser detectada correctamente por la tarjeta de adquisición de datos. La amplificación debe ser tal que las variaciones de la señal recorran todo el margen de la tarjeta de adquisición de datos. La amplificación de las señales, en su origen, reduce el ruido que les puede afectar en su transmisión hasta el computador.
- **Conversión por medio de optoacopladores:** Consiste en la conversión de una señal eléctrica en una señal óptica, de luz. El principal objetivo de esta conversión consiste

en aislar los sistemas eléctricos de los sensores de los sistemas eléctricos de la tarjeta de adquisición para que, de esta forma, se evite tener que usar masas comunes, que en algunos casos producen problemas de derivación de corrientes. Conviene que los sensores de calidad realicen esta conversión por medio de optoacopladores.

- **Filtrado:** Con el filtrado se pretende eliminar ruidos de alta frecuencia que pueden hacer perder exactitud al sistema de adquisición de datos. Lo ideal es transportar la señal del sensor lo más limpia posible a la tarjeta de adquisición.
- **Excitación:** Hay muchos sensores que necesitan de una excitación, bien en corriente, bien en tensión, para producir la variación proporcional a la magnitud a medir.
- **Linealización:** No todos los sensores tienen una variación lineal con respecto a las variaciones de la magnitud que se miden; a veces es necesario realizar unos cálculos para convertir la respuesta del sensor en lineal.

## 2.4 APRENDIZAJE AUTOMÁTICO

El aprendizaje automático es una técnica de análisis de datos que enseña a los ordenadores a hacer lo que resulta natural para las personas y los animales: aprender de la experiencia. Los algoritmos de aprendizaje automático emplean métodos de cálculo para aprender información directamente de los datos sin depender de una ecuación predeterminada como modelo. Los algoritmos mejoran su rendimiento de forma adaptativa a medida que aumenta el número de muestras disponibles para el aprendizaje. Los algoritmos de aprendizaje automático encuentran patrones naturales en los datos que generan conocimiento y contribuyen a tomar mejores decisiones y a realizar mejores predicciones. Considere el uso de aprendizaje automático cuando tenga una tarea o un problema complejo que implique una gran cantidad de datos y muchas variables, pero no disponga de ninguna fórmula o ecuación.

El aprendizaje automático emplea dos tipos de técnicas:

### El aprendizaje supervisado:

Crea un modelo que realiza predicciones en función de las pruebas en presencia de una incertidumbre, dicho modelo es entrenado con datos de entrada y salida conocidos para que pueda predecir salidas futuras, por lo tanto, en un algoritmo de aprendizaje supervisado toma un conjunto conocido de datos de entrada y respuestas conocidas para estos datos (salidas) y entrena un modelo con objeto de generar predicciones razonables como respuesta a datos nuevos. Utilice el aprendizaje supervisado si tiene datos conocidos para la salida que está intentando predecir. emplea técnicas de clasificación y regresión para desarrollar modelos predictivos. Utilice la clasificación si sus datos se pueden etiquetar, categorizar o dividir en grupos o clases concretos. Un modelo de aprendizaje supervisado se puede observar en la siguiente Figura 15.

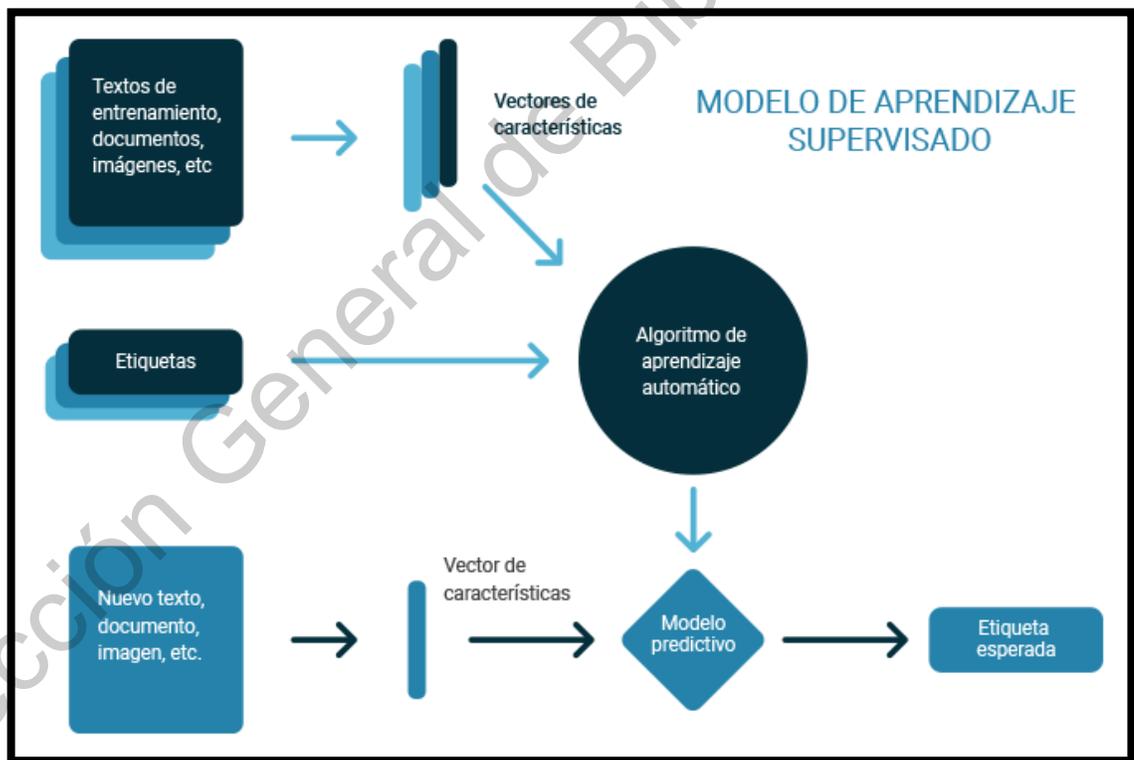


Figura 15. Diagrama de aprendizaje supervisado

### El aprendizaje no supervisado:

Encuentra patrones ocultos o estructuras intrínsecas en los datos de entrada. Se

emplea para inferir información a partir de conjuntos de datos que constan de datos de entrada sin respuestas etiquetadas. La técnica de aprendizaje no supervisado más común es el clustering, se emplea para el análisis de datos exploratorio, con objeto de encontrar patrones o agrupaciones ocultos en los datos. Un modelo de aprendizaje no supervisado se puede observar en la Figura 16 .

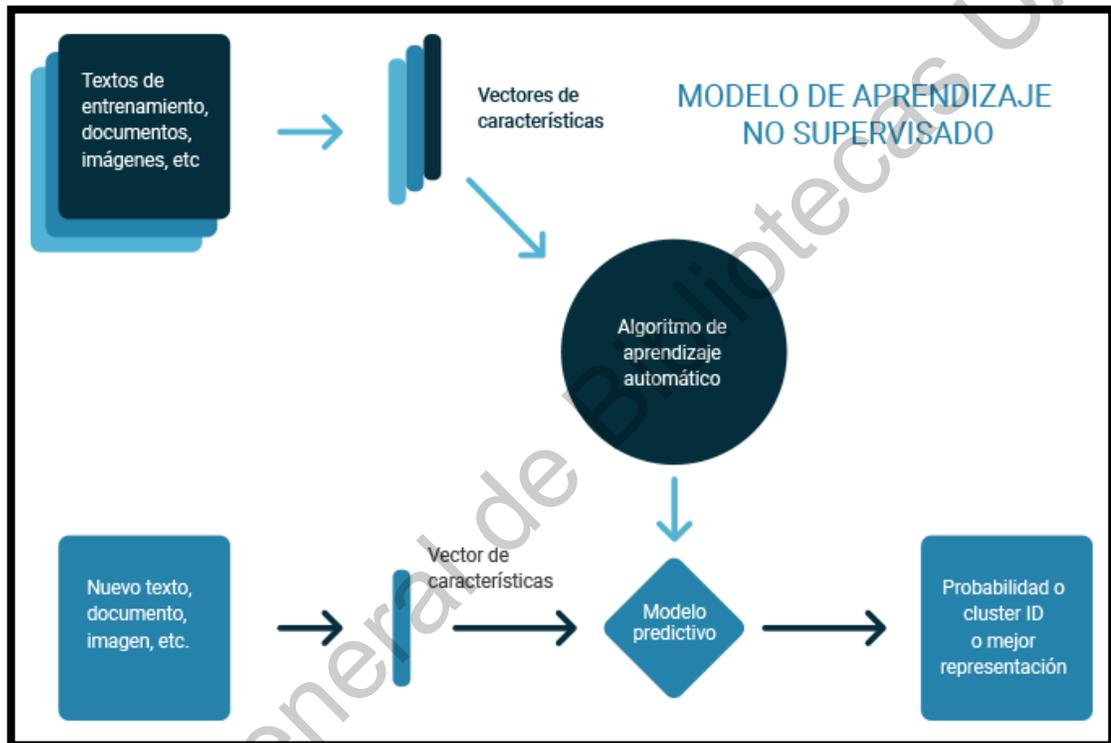


Figura 16. Diagrama de aprendizaje no supervisado

La elección del algoritmo adecuado puede parecer abrumadora; existen docenas de algoritmos de aprendizaje automático supervisados y no supervisados, y cada uno ofrece un enfoque distinto del aprendizaje.

### Técnicas basadas en el dominio del tiempo:

Las técnicas que basan su análisis en el dominio del tiempo son de las más efectivas para el análisis de señales en estado estacionario, y también algunas veces llegan a ser empleadas para señales en estado no estacionario.

Dentro de las técnicas de análisis de dominio del tiempo, además de incluir métodos estadísticos y estocásticos, también se pueden emplear técnicas de filtrado de datos, promedio de tiempo sincrónico y otros. En este sentido, debido al bajo costo computacional que representa hacer el cálculo de indicadores estadísticos, esta es la forma más sencilla de realizar un procesamiento sobre señales adquiridas. Los 15 datos estadístico-temporales más comunes son los siguientes:

### **Media ( $\bar{x}$ )**

Una media o también conocida como un promedio, es una medida de tendencia central. Se define como el valor característico de la serie de datos resultado de la suma de todas las observaciones dividido por el número total de datos.

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n |x_k| \quad (4)$$

### **Valor máximo ( $\hat{x}$ )**

La función de máximo es una función que se define en todo conjunto completamente ordenado que asigna a cada n-tupla de valores el máximo de dichos valores. El valor más grande de una distribución de valores  $x_k$  donde  $k = 1, 2, 3, \dots, m$ .

$$\hat{x} = \mathbf{max}(x_k) \quad (5)$$

### **Root mean square (RMS)**

Es una medida de la magnitud de la señal. Representa la amplitud constante de una señal para producir la misma potencia promedio que la señal original.

$$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k)^2} \quad (6)$$

### Square root mean (SRM)

Es una medida de la magnitud de la señal. Es la media generalizada con exponente de 0.5.

$$SRM = \left( \frac{1}{n} \sum_{k=1}^n \sqrt{|x_k|} \right)^2 \quad (7)$$

### Derivación estándar ( $\sigma$ )

Es una medida de la variabilidad o dispersión de un conjunto de datos respecto a su media.

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2} \quad (8)$$

### Varianza ( $\sigma^2$ )

La varianza poblacional de una población finita de tamaño  $n$ ,  $\sigma^2$ , es la desviación cuadrática promedio de cada número de su media. Representa la de qué tan dispersa es una distribución.

$$\sigma^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \quad (9)$$

### RMS shape factor ( $SF_{RMS}$ )

El shape factor o el factor de forma es la relación entre el valor RMS y la media matemática de los valores absolutos de todos los puntos en el conjunto de datos. El RMS shape factor es la combinación estadística del RMS y el shape factor.

$$SF_{RMS} = \frac{RMS}{\bar{x}} \quad (10)$$

### **SRM shape factor ( $SF_{SRM}$ )**

Es la combinación estadística del SRM y el shape factor.

$$SF_{SRM} = \frac{SRM}{\bar{x}} \quad (11)$$

### **Factor cresta ( $FC$ )**

El factor cresta es la relación entre el nivel máximo de la señal de entrada y el nivel RMS; por lo tanto, picos presentes en la señal en función del tiempo dan como resultado un aumento en el valor del factor de cresta

$$FC = \frac{\hat{x}}{RMS} \quad (12)$$

### **Latitud factor ( $LF$ )**

Respecto al factor cresta, la latitud factor es la relación entre el nivel máximo de la señal de entrada y el nivel SRM

$$LF = \frac{\hat{x}}{SRM} \quad (13)$$

### **Impulse factor ( $IF$ )**

Factor de impulso o impulse factor muestra la indicación de sobresaltos en la señal de tiempo.

$$IF = \frac{\hat{x}}{\bar{x}} \quad (14)$$

### **Skewness ( $S_{k3}$ )**

Es el tercer momento central normalizado y representa una medida de simetría. Una distribución o conjunto de datos es simétrica si tiene el mismo aspecto a la izquierda y a la derecha del punto central. Un skewnees positivo indica una distribución unilateral que se

apega a valores más positivos. Un skewness negativo indica una distribución unilateral que se extiende a valores más negativos.

$$S_{k3} = \frac{\sum_{k=1}^n (x_k - \bar{x})^3}{\sigma^3} \quad (15)$$

#### **Kurtosis ( $S_{k4}$ )**

Es el cuarto momento central normalizado. Describe como los datos están alrededor del pico máximo en comparación con una distribución normal. Puede indicar picos principales en un conjunto de datos y generalmente se usa para medir el tamaño de la cola de una distribución. La kurtosis positiva indica una distribución relativamente alta, mientras que una kurtosis negativa indica una distribución relativamente baja.

$$S_{k4} = \frac{\sum_{k=1}^n (x_k - \bar{x})^4}{\sigma^4} \quad (16)$$

#### **Quinto momento ( $S_{k5}$ )**

Los momentos de alto orden (más de cuatro) se calculan simplemente aumentando el factor de ecuación. Sin embargo, estos momentos de alto orden no tienen una interpretación descriptiva directa en las estadísticas.

$$S_{k5} = \frac{\sum_{k=1}^n (x_k - \bar{x})^5}{\sigma^5} \quad (17)$$

#### **Técnicas basadas en el dominio de la frecuencia:**

Las técnicas de procesamiento de señales basadas en el análisis de dominio de frecuencia realizan una transformación de las magnitudes físicas temporales a un espacio de dominio en frecuencia. Comúnmente el análisis basado en el dominio de frecuencia se realiza sobre mapas de frecuencia o espectros de frecuencias, estos espectros de frecuencias permiten realizar un análisis de las señales temporales en términos de las componentes de frecuencias individuales mediante el cálculo de la presencia relativa de cada una de las componentes.

La transformada rápida de Fourier (Fast Fourier Transform-FFT) es una de las técnicas más conocidas que se emplea para el análisis en dominio de frecuencia, el principio básico de la FFT es que cualquier señal arbitraria puede ser descompuesta en conjuntos de senoidales de diferentes frecuencias. En este sentido, un espectro de frecuencias obtenido a través la FFT se genera al proyectar una señal temporal en un conjunto de funciones básicas, donde cada uno de estos términos es una función senoidal con un único valor. Por lo tanto, cada uno de estos valores componen a la FFT (o el espectro de frecuencias) de la señal (Quiceno, 2009).

La siguiente formulación es empleada para poder hacer la transformación de señales de dominio en el tiempo a dominio de frecuencia empleando la FFT:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-2\pi ft} dt \quad (18)$$

donde  $x(t)$  es una señal continua en el dominio del tiempo y  $e^{-2\pi ft}$  representa las ondas básicas temporales; senos y cosenos combinados en formas compactas por medio del teorema de Euler. Desde un punto de vista más práctico, considerando que se realizó una adquisición de señales discreta, la FFT de este tipo de señales es obtenida por medio de la transformada discreta de Fourier (Discrete Fourier Transform-DFT) que se define como:

$$X[k] = \sum_{i=0}^{N-1} x_i e^{-j2\pi k \frac{i}{N}} \quad (19)$$

La DFT se calcula sobre un número finito de muestras temporales N de una señal discreta  $x_i$  con  $i=0, N-1$ , para obtener una aproximación espectral. Así como para señales de dominio en el tiempo, las señales espectrales también pueden ser caracterizadas por

indicadores estadísticos de frecuencia, y estos indicadores después son aplicados en acciones de condición de monitoreo y diagnóstico. Además de los indicadores estadísticos, existen indicadores característicos de falla para la mayoría de elementos rotatorios de las máquinas rotatorias (Villa-Cañas, 2015.).

### **Técnicas basadas en el dominio del tiempo-frecuencia:**

Las técnicas de procesamiento de señales basadas en el análisis de dominio de tiempo-frecuencia son un enfoque alternativo que trata de abordar las limitaciones y problemas de las técnicas de análisis basadas en el dominio del tiempo y frecuencia. Así como su nombre lo dice, las técnicas de análisis basado en dominio tiempo-frecuencia, describen de forma simultánea, el tiempo y componentes frecuenciales de las señales.

Estas técnicas son de gran utilidad en aquellos casos donde la maquinaria está sujeta a cambios transitorios de la velocidad, donde la FFT ya no es tan efectiva. Para el análisis de señales a partir de técnicas en el dominio tiempo-frecuencia se emplean distribuciones que pueden representar la energía, o la potencia de una señal en un espacio bidimensional de tiempo y frecuencia. Por lo tanto, una representación en el dominio tiempo-frecuencia, muestran como el contenido frecuencial varía a lo largo del tiempo. Existen diferentes técnicas que pueden ser empleadas para realizar un análisis en el dominio tiempo-frecuencia, entre las más conocidas están las siguientes:

### **Descomposición de modo empírico (EMD)**

La descomposición de modo empírico (EMD) fue propuesta como parte fundamental de la transformada de Hilbert-Huang (HHT). La transformada de Hilbert Huang se realiza en 2 etapas. En la primera etapa, usando el algoritmo EMD se obtienen funciones de modo intrínseco (IMF). Posteriormente, en una segunda etapa, se obtiene el espectro de frecuencia instantáneo de la serie inicial aplicando la transformada de Hilbert a los resultados del paso anterior.

El algoritmo EMD descompone cualquier conjunto de datos en funciones de modo

intrínseco (IMF) que no se establecen analíticamente y, en lugar de esto, se determinan mediante una sola serie analizada.

Las funciones básicas son en este caso obtenidas de forma adaptativa directamente a partir de los datos de entrada. Una IMF obtenida a partir de la EMD debe satisfacer solo los siguientes requisitos:

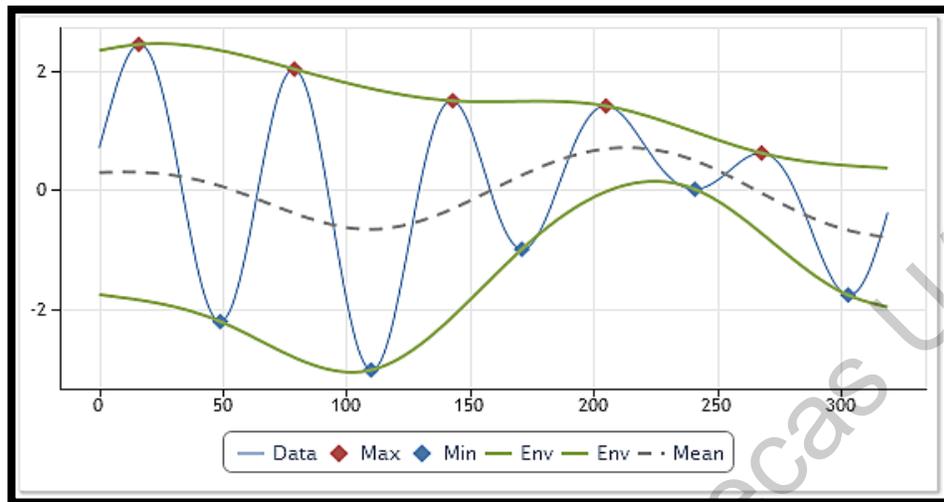
1. El número de IMF extrema (la suma del máximo y el mínimo) y el número de cruces cero deben ser iguales o distintos en al menos uno.
2. En cualquier punto de una IMF, el valor medio de la envolvente definida por el máximo local y la definida por el mínimo local deben ser cero.

La descomposición da como resultado una familia de componentes IMF ordenados según la frecuencia. Cada IMF contiene oscilaciones con una frecuencia inferior a la precedente.

La motivación del método de Descomposición Empírica de Modos es poder tratar con sistemas no lineales y no estacionarios y, por lo tanto, con señales cuya frecuencia instantánea depende del tiempo.

Este algoritmo, propuesto por Huang, se basa en generar envolventes de ajuste definidas por máximos (Max) y mínimos (Min) de una serie y la consiguiente sustracción de la media (Mean) de estas envolventes (Env) a la serie inicial.

Esto requiere la identificación de todos los extremos locales que están conectados por líneas de esplines cúbicos para producir las envolventes superiores e inferiores. El procedimiento para trazar las envolventes se muestra en la Figura 17 .

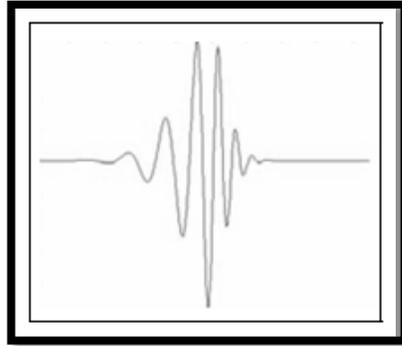


**Figura 17. Envolventes de la EMD**

### **Análisis tiempo-frecuencia con Wavelets**

En el análisis mediante Wavelets se realiza un proceso de la señal que proporciona información en tiempo y en frecuencia. Esto permite el análisis de disturbios no estacionarios, transitorios oscilatorios o impulsivos, o fluctuaciones de tensión donde la FFT tendría fuertes limitantes (Quiceno, 2009.). Básicamente se puede decir que los requisitos que debe tener una onda para que sea un análisis wavelet son:

- Tiene que ser oscilatoria.
- Tiene que decrecer rápidamente a un valor de cero (en periodo pequeño, la función es diferente de cero).
- Tiene un valor medio nulo.
- En la Figura 18 se muestra un ejemplo de un análisis Wavelet.

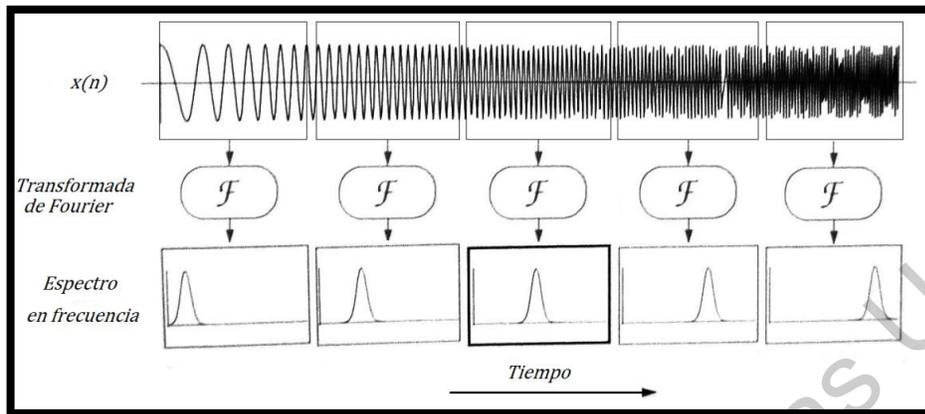


**Figura 18. Wavelet Daubechies (www.mathworks.com)**

Por medio de una transformada Wavelet, se representa la señal original como la suma de Wavelets en distintas localizaciones (posiciones) y escaladas (duración). Los coeficientes de la transformada son los pesos de cada Wavelet para representar la señal en esas localizaciones y escalas. La transformada Wavelet discreta (*Discrete Wavelet Transform-DWT*) es suficiente para descomponer y reconstruir la mayoría de las fallas en máquinas o herramientas eléctricas. Brinda suficiente información y su uso significa una importante reducción en tiempos de operación computacional. Una de las transformadas Wavelet continuas más utilizadas es la Morlet, esta puede ser empleada en el análisis de señales de sistemas no lineales por el buen soporte que tiene tanto en frecuencia como en el tiempo.

#### **Análisis tiempo-frecuencia con la transformada corta de Fourier**

Existe una posibilidad de analizar una señal en tiempo-frecuencia con transformadas de Fourier consecutivas y de corta duración, a esto se le llama transformada corta de Fourier (Short-Time Fourier Transform-STFT). El análisis de la STFT consiste en tomar pequeñas secciones en intervalos de tiempo de una señal realizando un ventaneado al cual se calcula la FFT en esa sección y así poder conocer los componentes frecuenciales de esa sección. Así analizando cada transformada de Fourier se observa el cambio de dichas componentes frecuenciales en el tiempo, la Figura 19 muestra la interpretación de la STFT en una señal (Quiceno, 2009).



**Figura 19. Interpretación de la STFT (Rao et al., 2011)**

La elección del tamaño de la ventana es crítica a la hora de obtener buena resolución. Si lo que se desea es obtener una resolución grande en el dominio temporal, se elige una ventana de poca longitud, en cambio, la distribución espectral estará muy dispersa y no se podrán conocer con exactitud sus componentes. Por el contrario, la elección de una ventana grande mostrará con mayor precisión las componentes de frecuencia, pero se perderá idea del momento en que se produjeron cada una de ellas.

## 2.5 REDUCCIÓN DE CARACTERÍSTICAS

### Análisis de componentes principales (PCA)

El análisis de componentes principales (principal component analysis, PCA o ACP) es una de las técnicas de aprendizaje no supervisado, las cuales suelen aplicarse como parte del análisis exploratorio de los datos. Un problema central en el análisis de datos multivalentes es la reducción de la dimensionalidad: si es posible describir con precisión los valores de  $p$  variables por un pequeño subconjunto  $r < p$  de ellas, se habrá reducido la dimensión del problema a costa de una pequeña pérdida de información.

El análisis de componentes principales tiene este objetivo: dadas  $n$  observaciones de  $p$  variables, se analiza si es posible representar adecuadamente esta información con un número menor de variables construidas como combinaciones lineales de las originales. Por ejemplo, con variables con alta dependencia es frecuente que un pequeño número de nuevas

variables (menos del 20 por 100 de las originales) expliquen la mayor parte (más del 80 por 100 de la variabilidad original).

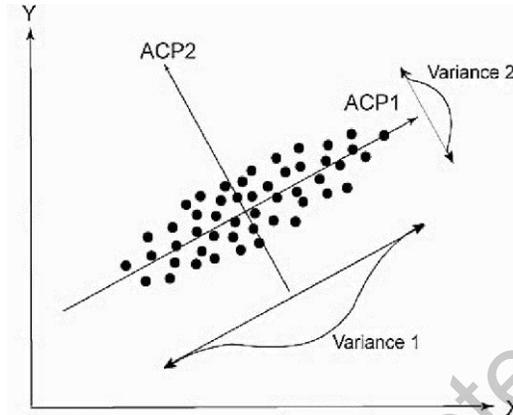


Figura 20. Los dos componentes principales más importantes

Suponiendo que se dispone de los valores de  $p$ -variables en  $n$  elementos de una población dispuestos en una matriz  $\mathbf{X}$  de dimensiones  $n \times p$ , donde las columnas contienen las variables y las filas los elementos (observaciones). Imaginando que previamente se ha restado a cada variable su media, de manera que las variables de la matriz  $\mathbf{X}$  tienen media cero y su matriz de covarianzas vendrá dada por  $1/n \mathbf{X}'\mathbf{X}$ . El problema que se desea resolver es encontrar un espacio de dimensión más reducida que represente adecuadamente los datos.

### Cálculo del primer componente principal (ACP1)

El primer componente principal se define como la combinación lineal de las variables originales que tiene varianza máxima. Los valores en este primer componente de los  $n$  individuos se representarán por un vector  $z_1$ , dado por:

$$z_1 = \mathbf{X}a_1 \quad (20)$$

Como las variables originales tienen media cero también  $z_1$  tendrá media nula. Su varianza será la ecuación 21.

$$\frac{1}{n} z_1' z_1 = \frac{1}{n} a_1' X' X a_1 = a_1' S a_1 \quad (21)$$

donde  $S$  es la matriz de varianzas y covarianzas de las observaciones. Es obvio que se puede maximizar la varianza sin límite aumentando el módulo del vector  $a_1$ . Para que la maximización de la ecuación anterior tenga solución se debe imponer una restricción al módulo del vector  $a_1$ , y, sin pérdida de generalidad, imponiendo que  $a_1' a_1 = 1$ .

Se introduce esta restricción mediante el multiplicador de Lagrange:

$$M = a_1' S a_1 - \lambda (a_1' a_1 - 1) \quad (22)$$

y se maximiza esta expresión de la forma habitual derivando respecto a los componentes de  $a_1$  e igualando a cero. Entonces, se tiene la ecuación 23.

$$\frac{\partial M}{\partial a_1} = 2S a_1 - 2\lambda a_1 = 0 \quad (23)$$

cuya solución es la ecuación 24.

$$S a_1 = \lambda a_1 \quad (24)$$

Esto implica que  $a_1$  es un vector propio de la matriz  $S$ , y  $\lambda$  su correspondiente valor propio. Para determinar qué valor propio de  $S$  es la solución de la ecuación anterior, multiplicando por la izquierda por  $a_1'$  la ecuación 25.

$$a_1' S a_1 = \lambda a_1' a_1 = \lambda \quad (25)$$

y se concluye, por la ecuación (21), que  $\lambda$  es la varianza de  $z_1$ . Como ésta es la cantidad que

se quiere maximizar,  $\lambda$  será el mayor valor propio de la matriz  $S$ . Su vector asociado,  $a_1$ , define los coeficientes de cada variable en el primer componente principal.

### Cálculo del segundo componente (ACP2)

Se va a obtener el mejor plano de proyección de las variables  $X$ . se calculara estableciendo como función objetivo que la suma de las varianzas de  $z_1 = Xa_1$  y  $z_2 = Xa_2$  sea máxima, donde  $a_1$  y  $a_2$  son los vectores que definen el plano. La función objetivo será dada por la ecuación 26.

$$\phi = a_1' S a_1 + a_2' S a_2 - \lambda_1 (a_1' a_1 - 1) - \lambda_2 (a_2' a_2 - 1) \quad (26)$$

que incorpora las restricciones de que las direcciones deben de tener módulo unitario ( $a_i' a_i = 1, i = 1, 2$ ). Derivando e igualando a cero:

$$\frac{\partial \phi}{\partial a_1} = 2S a_1 - 2\lambda_1 a_1 = 0 \quad (27)$$

$$\frac{\partial \phi}{\partial a_2} = 2S a_2 - 2\lambda_2 a_2 = 0 \quad (28)$$

la solución de este sistema es:

$$S a_1 = \lambda_1 a_1 \quad (29)$$

$$S a_2 = \lambda_2 a_2 \quad (30)$$

que indica que  $a_1$  y  $a_2$  deben ser vectores propios de  $S$ . Tomando los vectores propios de norma uno y sustituyendo en la ecuación (26), se obtiene que, en el máximo, la función objetivo es:

$$\phi = \lambda_1 + \lambda_2 \quad (31)$$

es claro que  $\lambda_1$  y  $\lambda_2$  deben ser los dos autovalores mayores de la matriz  $S$  y  $a_1$  y  $a_2$  sus correspondientes autovectores. Se observa que la covarianza entre  $z_1$  y  $z_2$ , dada por  $a_1' S a_2$  es cero ya que  $a_1' a_2 = 0$ , y las variables  $z_1$  y  $z_2$  estarán incorreladas según Blanco (2018).

## 2.6 CLASIFICACIÓN

### Algoritmo K Vecinos más Cercanos (KNN)

La idea es realmente sencilla: el algoritmo clasifica cada dato nuevo en el grupo que corresponda, según tenga  $k$  vecinos más cerca de un grupo o de otro. Es decir, calcula la distancia del elemento nuevo a cada uno de los existentes, y ordena dichas distancias de menor a mayor para ir seleccionando el grupo al que pertenecer.

Este grupo será, por tanto, el de mayor frecuencia con menores distancias.

El K-NN es un algoritmo de aprendizaje supervisado, es decir, que a partir de un juego de datos inicial su objetivo será el de clasificar correctamente todas las instancias nuevas. El juego de datos típico de este tipo de algoritmos está formado por varios atributos descriptivos y un solo atributo objetivo (también llamado clase).

En contraste con otros algoritmos de aprendizaje supervisado, K-NN no genera un modelo fruto del aprendizaje con datos de entrenamiento, sino que el aprendizaje sucede en el mismo momento en el que se prueban los datos de test.

A este tipo de algoritmos se les llama métodos de aprendizaje perezoso. Por lo tanto, el algoritmo KNN sigue los siguientes pasos.

1. Calcula la distancia entre el dato a clasificar y el resto de datos del conjunto de muestras de entrenamiento.
2. Selecciona los “ $k$ ” elementos más cercanos (con menor distancia, según la función que se use).

- Realizar una “votación de mayoría” entre los k puntos: los de una clase/etiqueta que dominen va a decidir su clasificación final.

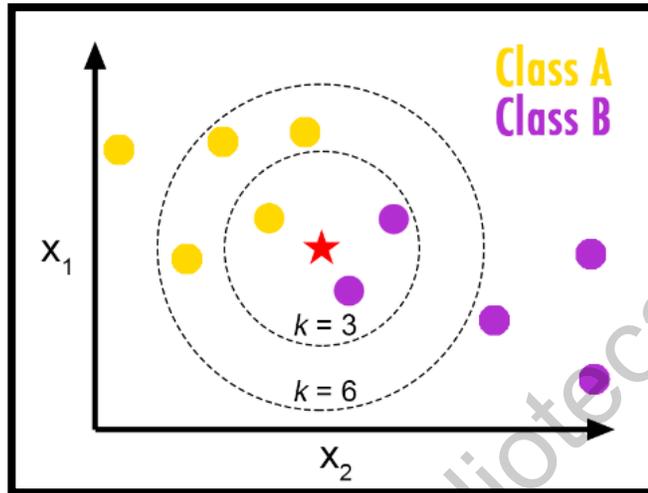


Figura 21. Clasificación con K vecinos más cercanos

Teniendo en cuenta el punto 3, se verá que para decidir la clase de un punto es muy importante el valor de k, pues este terminará casi por definir a qué grupo pertenecerán los puntos, sobre todo en las fronteras entre grupos. Por ejemplo, se utilizan valores impares de k para desempatar. No será lo mismo tomar para decidir 3 valores que 13. Esto no quiere decir que necesariamente tomar más puntos implique mejorar la precisión.

Lo que es seguro es que cuantos más puntos k se tienen más tardará el algoritmo en procesar y dar respuesta. Las formas más populares de medir la cercanía entre puntos son la distancia Euclidiana.

Por ejemplo en el plano cartesiano sean los puntos  $A = (x_A; y_A)$  y  $B = (x_B; y_B)$  se define la distancia euclideana entre dichos puntos por la ecuación 32.

$$d(A, B) = \sqrt{(x_B - x_A)^2 + (y_B - y_A)^2} \quad (32)$$

Por ejemplo, en la Figura 21 se muestra unos puntos donde existen dos tipos de clases, la clase A y la clase B. Cuando se agrega un nuevo dato representado por la estrella.

Por lo tanto, se calculan las distancias euclidianas del nuevo dato a todos los puntos y se toman los más cercanos a dicho nuevo dato, así que, la clasificación dependerá del valor de  $k$ .

## Red neuronal

Las Redes Neuronales fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, constituidos por un conjunto de unidades llamadas neuronas o nodos conectados unos con otros.

Una neurona consta de tres partes:

1. El cuerpo de la neurona
2. Las dendritas, que reciben las entradas
3. El axón, que lleva la salida de la neurona a las dendritas de otras neuronas

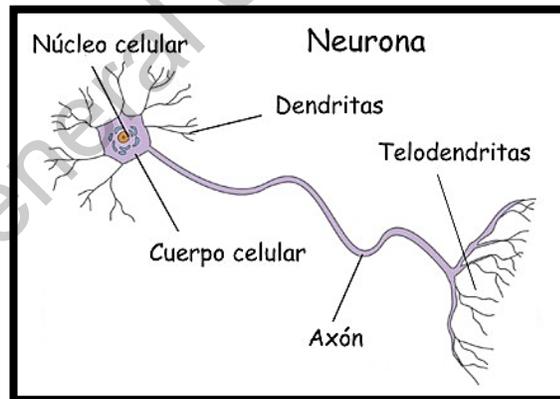


Figura 22. Neurona biológica

El primer modelo de red neuronal fue propuesto en términos de un modelo computacional de actividad nerviosa. Este modelo era un modelo binario, donde cada neurona tenía un escalón o umbral prefijado, y sirvió de base para los modelos posteriores.

Una primera clasificación de los modelos de NN es:

## 1. Modelos inspirados en la Biología:

Estos comprenden las redes que tratan de simular los sistemas neuronales biológicos, así como ciertas funciones como las auditivas o de visión. El objetivo principal de las redes neuronales de tipo biológico es desarrollar operaciones de síntesis y procesamiento de información, relacionadas con los sistemas biológicos. La forma completa en la que dos neuronas se relacionan no es totalmente conocida, y depende además del tipo particular de cada neurona. En general, una neurona envía su salida a otras por su axón, y éste lleva la información por medio de diferencias de potencial eléctrico. Las neuronas y las conexiones entre ellas (sinapsis) constituyen la clave para el procesamiento de la información.

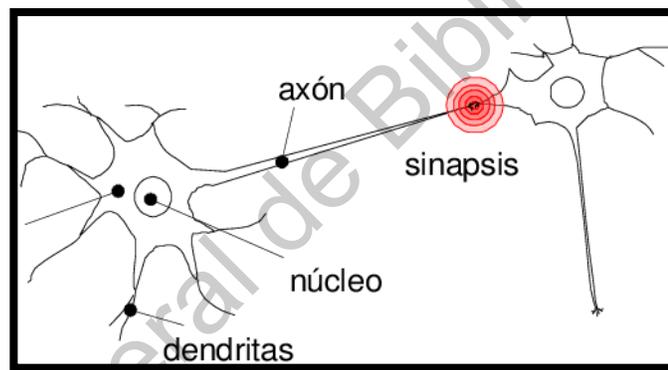


Figura 23. Sinapsis de una neurona biológica

## 2. Modelos artificiales aplicados:

Estos modelos no tienen por qué guardar similitud estricta con los sistemas biológicos. Sus arquitecturas están bastante ligadas a las necesidades de las aplicaciones para las que son diseñados. Están inspiradas en las redes neuronales biológicas, aunque poseen otras funcionalidades y estructuras de conexión distintas a las vistas desde la perspectiva biológica. Las características principales de las NN son las siguientes:

1. Auto-Organización y Adaptabilidad: utilizan algoritmos de aprendizaje adaptativo y auto-organización, por lo que ofrecen mejores posibilidades de

procesado robusto y adaptativo.

2. Procesado no Lineal: aumenta la capacidad de la red para aproximar funciones, clasificar patrones y aumenta su inmunidad frente al ruido.
3. Procesado Paralelo: normalmente se usa un gran número de nodos de procesado, con alto nivel de interconectividad.

El elemento básico de computación (modelo de neurona) se le llama habitualmente nodo o unidad. Recibe un input desde otras unidades o de una fuente externa de datos. Cada input tiene un peso asociado  $w$ , que se va modificando en el llamado proceso de aprendizaje. Cada unidad aplica una función dada  $f$  de la suma de los inputs ponderadas mediante los pesos.

$$y_i = \sum_j w_{ij} y_j \quad (33)$$

Posee cierto número de entradas (ya sean estos datos originales o bien salidas de otras neuronas de la red). Cada entrada proviene de una conexión que tiene cierta fuerza (o peso), lo que se denomina. Estos pesos corresponden con la eficacia sináptica de una neurona biológica.

Cada neurona tiene también un cierto valor umbral. En el interior de la neurona se suman las entradas, y a esta suma se le resta el valor umbral propio de la neurona. Esto genera la activación de la neurona, también conocida como potencial post-sináptico o PSP. La señal de activación se procesa mediante una función de activación, también conocida como función de transferencia, que da lugar a la salida de la neurona.

El siguiente esquema muestra la equivalencia entre los componentes de las neuronas biológicas y los de las neuronas artificiales.

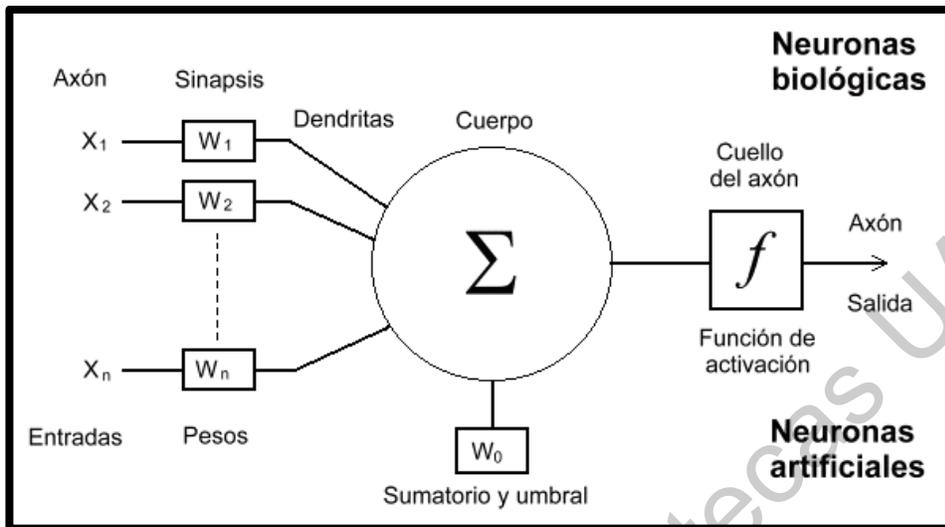


Figura 24. Esquema de una neurona artificial

Hay dos fases en la modelización con redes neuronales:

#### Fase de entrenamiento:

Se usa un conjunto de datos o patrones de entrenamiento para determinar los pesos (parámetros) que definen el modelo de red neuronal. Se calculan de manera iterativa, de acuerdo con los valores de los valores de entrenamiento, con el objeto de minimizar el error cometido entre la salida obtenida por la red neuronal y la salida deseada.

#### Fase de Prueba:

En la fase anterior, el modelo puede que se ajuste demasiado a las particularidades presentes en los patrones de entrenamiento, perdiendo su habilidad de generalizar su aprendizaje a casos nuevos (sobreajuste). Para evitar el problema del sobreajuste, es aconsejable utilizar un segundo grupo de datos diferentes a los de entrenamiento, el grupo de validación, que permita controlar el proceso de aprendizaje.

# CAPÍTULO III

## 3. METODOLOGÍA

En este capítulo se presentan las metodologías propuestas para cumplir los objetivos de este trabajo. Se proponen dos metodologías, la primera, se enfoca en procesamiento de señales para validación de las técnicas a utilizar, en la segunda, se propone una metodología para el desarrollo del sensor inteligente.

Por lo que la primera metodología será utilizada para fase de pruebas y comparación de técnicas, mientras que la segunda será utilizada para la ejecución de las mejores técnicas según los resultados de la anterior ya que en un sensor inteligente se debe de tener una programación concreta y específica.

En la Figura 25 se muestra el diagrama propuesto representativo de la metodología completa utilizada para el diagnóstico de fallas en rodamientos de un motor de inducción. Primero, se realizó la instrumentación del motor de inducción, para poder medir las magnitudes físicas (vibración y corriente) por medio de un acelerómetro triaxial y pinzas de corriente respectivamente; después, bajo diferentes frecuencias de operación (5 frecuencias diferentes) se evaluaron 3 condiciones de rodamiento cerámico y 3 condiciones de rodamiento metálico, y para cada una de las condiciones evaluadas, se hizo la adquisición de corriente y voltaje.

La base de datos fue adquirida y almacenada en la PXI mediante la plataforma LabVIEW SignalExpress. La parte del monitoreo, es decir, el procesamiento de señales, cálculos característicos, reducción de características, clasificación, validación de técnicas y diagnóstico fue realizado por medio de MATLAB® en la computadora personal.

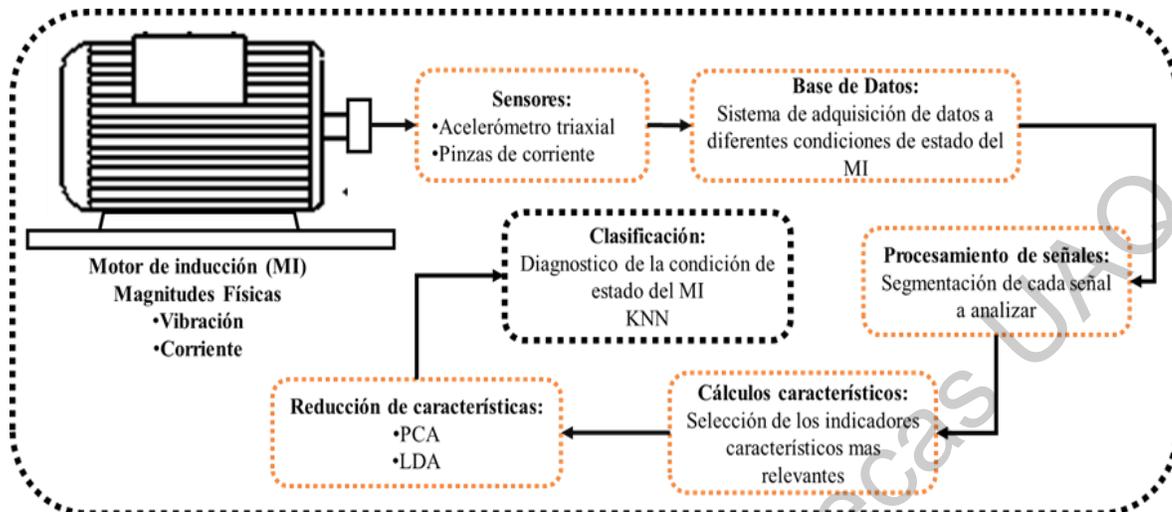


Figura 25. Diagrama de la metodología general propuesta

### Banco de pruebas

Inicialmente se contaba con un banco de pruebas como se muestra en la Figura 26, donde se tenía un motor de inducción que por medio de un acoplamiento contenía un eje con tres rodamientos, el rodamiento central sería el rodamiento al que se le fabricarían las fallas para posteriormente hacer la adquisición de la base de datos, sin embargo, en este momento no se contaba con el material necesario para montar dicho sistema descrito de tal manera que no existiera desalineamiento mínimo que el acoplamiento logrará hacerlo despreciable, por lo tanto, el desalineamiento tanto angular como paralelo generó vibraciones que lograron dañar el rodamiento donde se estaban experimentando las fallas.

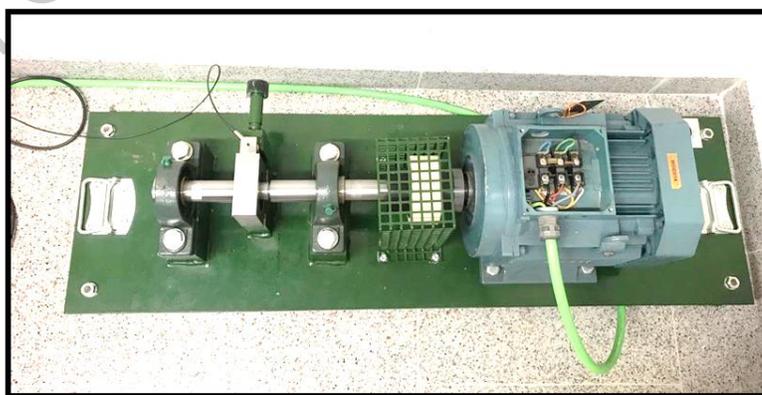


Figura 26. Banco de pruebas previo

Finalmente, se optó por hacer la fabricación de las fallas en los rodamientos de pruebas para adquisición de la base de datos, los rodamientos tanto metálicos como cerámicos fueron montados por el lado del ventilador del motor donde se muestra la flecha roja en la Figura 27, por lo que, en cada registro de datos de vibración y de corriente de cada rodamiento sano o con alguna severidad de falla específica, el motor fue desmontado y el rodamiento remplazado.

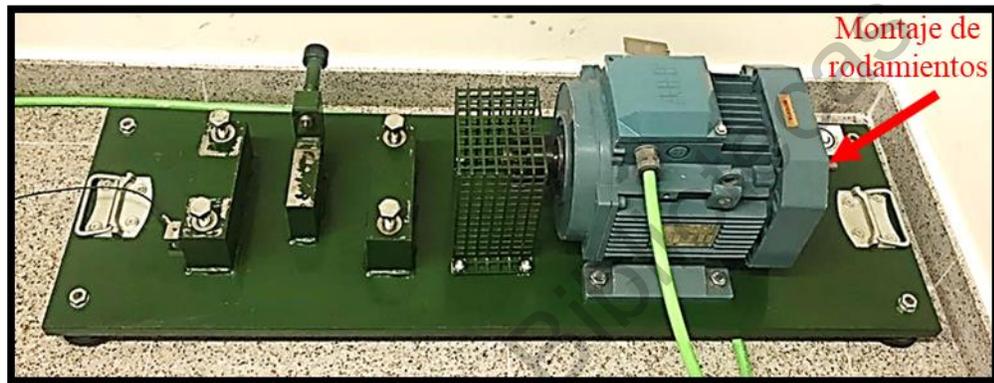


Figura 27. Banco de pruebas utilizado

Las especificaciones del motor de inducción utilizado se muestran en placa que contiene la Figura 28, donde las principales características son que es un motor trifásico, con una velocidad nominal de 50 Hz por lo que se cuenta con 3000 revoluciones por minuto (RPM) y su protección mecánica clase 55 (IP 55) con protección al polvo y al agua.

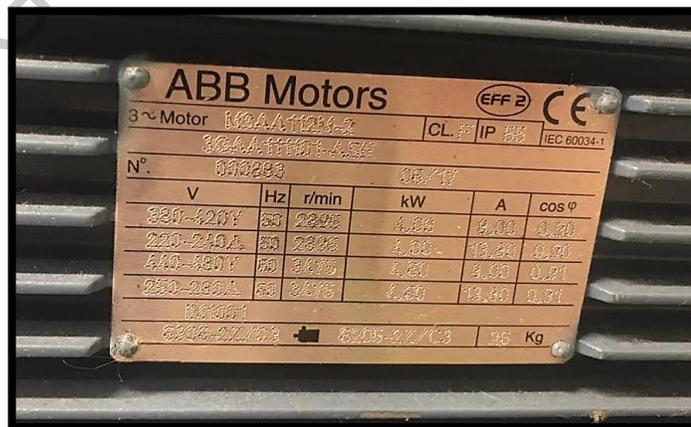


Figura 28. Placa característica del motor utilizado

## Sensores

El sensor utilizado en la adquisición de datos de vibración fue el acelerómetro KS943B.100, las especificaciones más importantes de dicho sensor son:

- Sensibilidad de voltaje:  $100 \frac{mV}{g} \pm 5\%$
- Rango:  $\pm 60g$
- Límite de destrucción: 8000g
- Rango de frecuencia: 22000Hz
- Ruido residual (RMS, 3Hz-50kHz):  $< 600\mu g$
- Suministro de corriente constante: 2-20mA
- Voltaje de salida: 12-14V
- Enchufe: Binder 707

La señal se adquirió a 5000 muestras por segundo tanto en vibración como en corriente, las pinzas de corriente utilizadas en cada fase de la alimentación del motor como el acelerómetro ya descrito se muestran en la Figura 29.

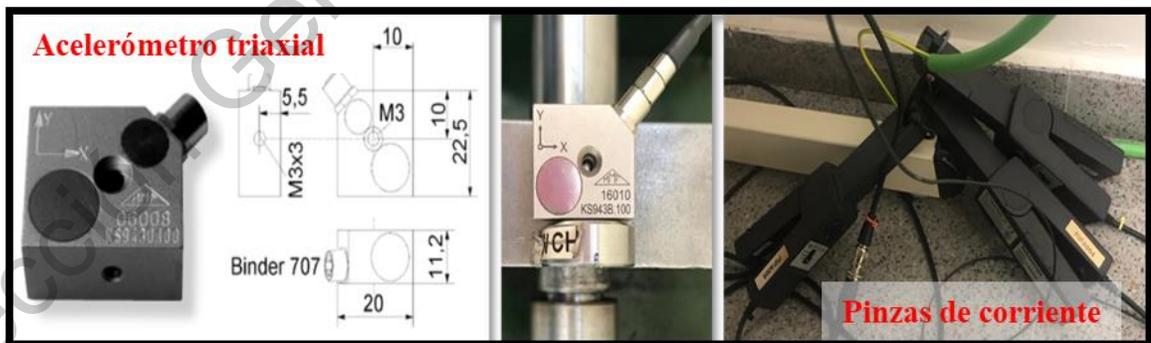


Figura 29. Sensores Utilizados (Acelerómetro y pinzas de corriente)

## Base de datos

Para la adquisición de la base de datos se utilizó la **NI PXIe-1062Q** que se define

como extensiones PCI para Instrumentación (PXI) es una plataforma basada en PC que ofrece una solución de despliegue de alto rendimiento y bajo costo para sistemas de medida y automatización. PXI combina el bus eléctrico de Interconexión de Componentes Periféricos (PCI) con el robusto y modular paquete Eurocard de CompactPCI, y añade buses de sincronización especializados y características clave de software. PXI también añade características mecánicas, eléctricas y de software que definen sistemas completos para aplicaciones de pruebas y medidas, de adquisición de datos y de manufactura. Estos sistemas son útiles para aplicaciones tales como militares, aeroespaciales y automotrices; y para pruebas tales como de manufactura e industriales.

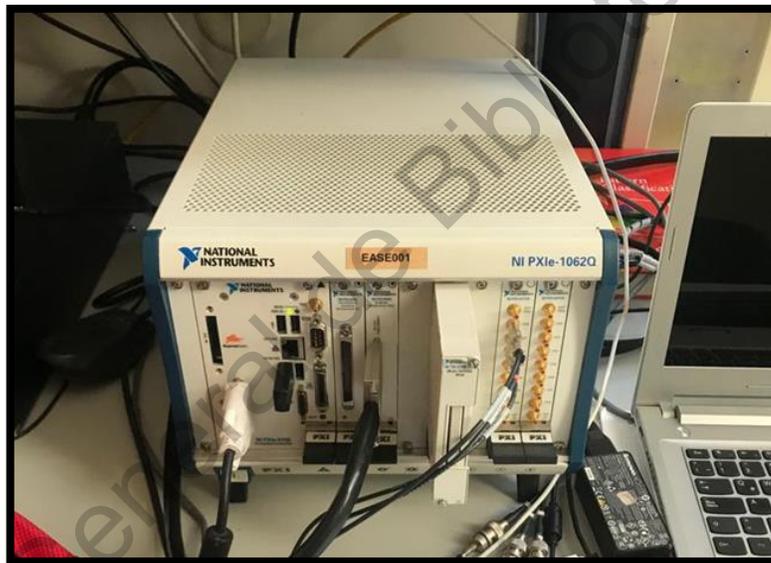


Figura 30. NI PXIe-1062Q.

La plataforma utilizada para la adquisición de datos con la PXI fue **LabVIEW SignalExpress** es un software interactivo de registro de datos para adquirir, analizar y presentar datos rápidamente desde cientos de dispositivos e instrumentos de adquisición de datos. Los usuarios de SignalExpress pueden controlar más de 400 instrumentos independientes y basados en PC, así como registrar datos de más de 250 dispositivos de adquisición de datos. Las señales pueden procesarse y analizarse, y las señales resultantes pueden enviarse a dispositivos de hardware. Con SignalExpress, las aplicaciones se pueden escalar con generación automática de códigos de LabVIEW. Los reportes personalizados se

pueden crear y exportar fácilmente a LabVIEW, DIAdem o Microsoft Excel. La plataforma con la señales de corrientes luce como en la Figura 31.

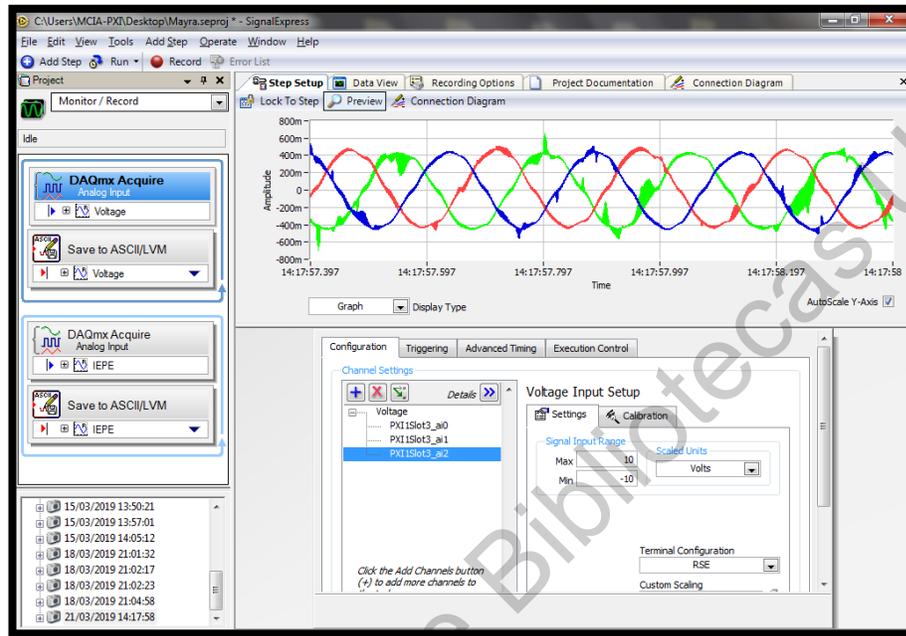


Figura 31. Plataforma LabVIEW SignalExpress

## La base de datos de Case Western Reserve University

Con el fin de comprender mejor las técnicas a implementar en este trabajo, además de fabricar las fallas propias, también se hizo uso de la base de datos de rodamientos que se encuentra en un sitio de internet de la Case Western Reserve University. Este sitio web proporciona acceso a datos de prueba de rodamientos de bolas para rodamientos normales y defectuosos. Los experimentos se realizaron usando un motor eléctrico de 2 hp, y los datos de aceleración se midieron en ubicaciones cercanas y alejadas de los cojinetes del motor. Estas páginas web son únicas en el sentido de que las condiciones de prueba del motor son reales, así como el estado de falla del rodamiento, se han documentado cuidadosamente para cada experimento.

Las fallas cojinetes del motor se fabricaron utilizando mecanizado por electrodescarga (EDM). Las fallas que van desde 0.007 pulgadas de diámetro a 0.040 pulgadas de diámetro se introdujeron por separado en la pista de rodamiento interior, el elemento rodante

(es decir, la bola) y la pista de rodamiento exterior. Los rodamientos con fallas se reinstalaron en el motor de prueba y se registraron datos de vibraciones para cargas de motor de 0 a 3 caballos de fuerza (velocidades del motor de 1797 a 1720 RPM).

## Procesamiento de señales

Para el procesamiento de señales cálculos característicos, reducción de características, clasificación, y validación de las técnicas utilizadas se hizo el uso de MATLAB® (MATrix LABoratory, laboratorio de matrices) es un sistema de cómputo numérico que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio (lenguaje M). Entre sus prestaciones básicas se hallan la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, la creación de interfaces de usuario (GUI) y la comunicación con programas en otros lenguajes y con otros dispositivos hardware. La plataforma de programación de Matlab luce como la Figura 32.

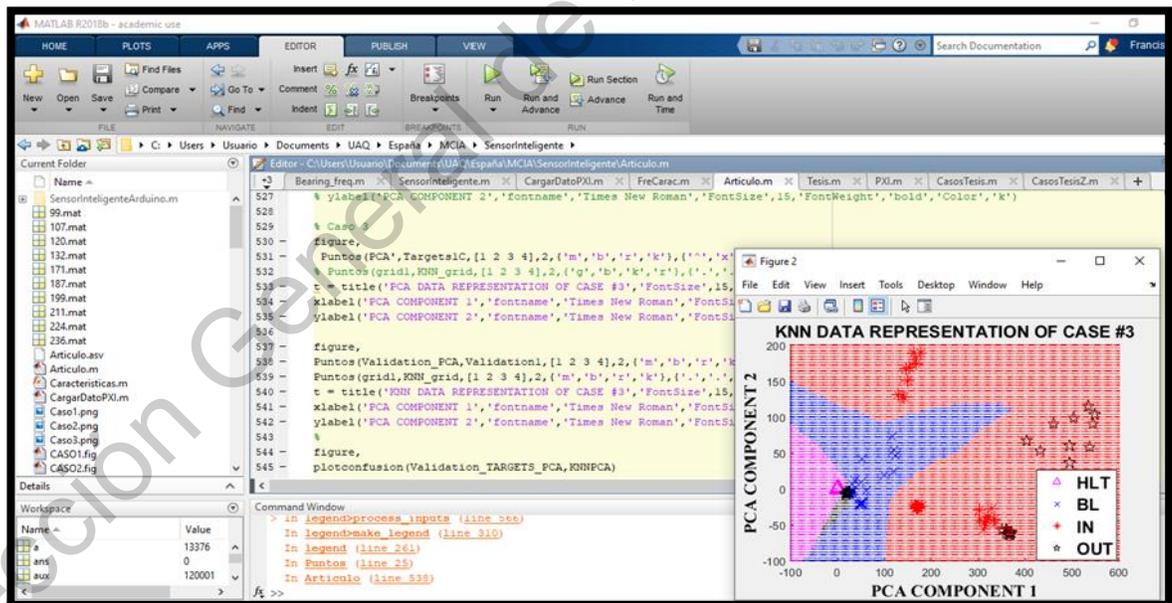


Figura 32. Plataforma de MATLAB

Sus características principales son:

- Lenguaje de alto nivel para cálculos científicos y de ingeniería

- Entorno de escritorio optimizado para la exploración iterativa, el diseño y la solución de problemas
- Gráficas para visualizar datos y herramientas para crear diagramas personalizados
- Aplicaciones para ajustar curvas, clasificar datos, analizar señales, ajustar sistemas de control y muchas otras tareas
- Cajas de herramientas complementarias para una amplia variedad de aplicaciones científicas y de ingeniería
- Herramientas para crear aplicaciones con interfaces de usuario personalizadas
- Interfaces para C/C++, Java®, .NET, Python, SQL, Hadoop y Microsoft® Excel®

### **Proceso de segmentación**

Debido al comportamiento no lineal, a condiciones de operación y/o ruido en la maquinaria, la información extraída de las señales varía para cada muestra, dificultando así el análisis que permita una correcta detección y clasificación de fallas. Para dar una solución a este problema, una de las propuestas empleadas se basa en el cálculo de características estadístico-temporales.

La extracción y evaluación de características estadístico-temporales se basan en un previo procesamiento de señal, en este caso, se utilizará la segmentación de señales de vibración y corriente. Esta segmentación divide la señal completa en tramos que sean lo suficientemente representativos.

El tiempo de adquisición que se utilizó en cada señal de corriente y vibración a diferente velocidad del motor fue de 100 segundos, y cada segundo contiene 5000 muestras por lo que la señal completa contiene medio millón de muestras. Entonces, se optó por

segmentar la señal en 5000 muestras, por lo tanto se cuenta con 100 segmentaciones o tramos. Un diagrama representativo de la señal se puede observar en la Figura 33.

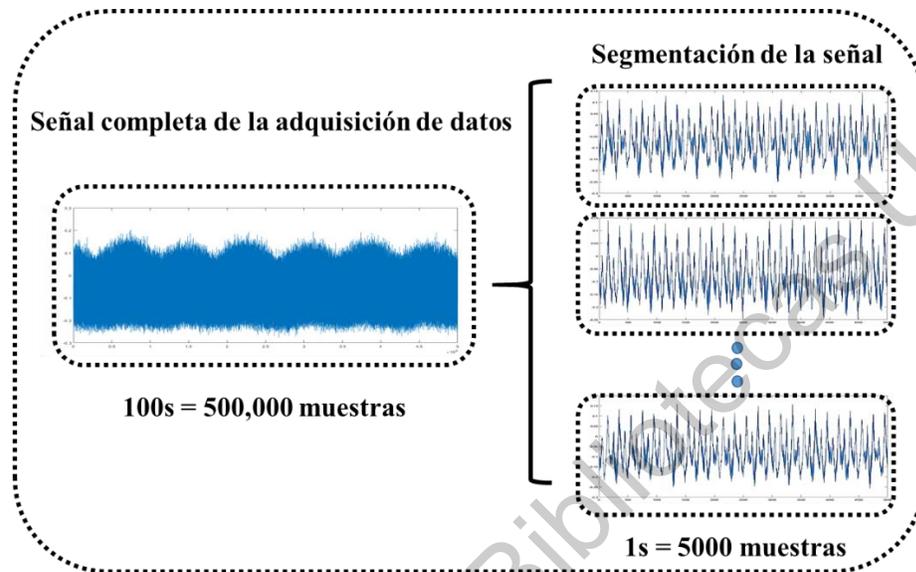


Figura 33. Segmentación

### Cálculos característicos

Después de la segmentación y conseguir los 100 tramos de cada señal a analizar, y con el objetivo de realzar la información más importante de cada tramo, se realizan los cálculos de características estadístico-temporales. Con ello, se puede hacer una buena descripción de la condición del sistema.

En esta metodología, se hará un procesamiento previo a esta etapa, que son las técnicas tiempo-frecuencia. Aunque la aplicación del análisis previo de las técnicas tiempo frecuencia mejora la caracterización, también va a incrementar el consto computacional, por lo que se recomienda aplicarlas solo en sistemas difíciles de clasificar. Los cálculos característicos estadístico-temporales utilizados en esta metodología fueron 8 (Tabla 4): media, valor máximo, RMS, factor forma (con RMS), factor cresta, factor impulso, oblicuidad y kurtosis.

Tabla 4. Cálculos característicos estadístico-temporales utilizados

<b>Media</b>	$\bar{x} = \frac{1}{n} \sum_{k=1}^n  x_k $
<b>Valor máximo</b>	$\hat{x} = \max(x_k)$
<b>RMS</b>	$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k)^2}$
<b>Factor forma (con RMS)</b>	$SF_{RMS} = \frac{RMS}{\bar{x}}$
<b>Factor cresta</b>	$FC = \frac{\hat{x}}{RMS}$
<b>Factor impulso</b>	$IF = \frac{\hat{x}}{\bar{x}}$
<b>Oblicuidad</b>	$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^3}{\sigma^3}$
<b>Kurtosis</b>	$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^4}{\sigma^4}$

### Reducción de características

Cuando se finaliza el proceso anterior, se debe de tener una matriz de 100 tramos de señal por los 8 indicadores característicos para cada señal analizada, por lo tanto, tener un conjunto de alta dimensionalidad implica un alto consumo computacional, además que irremediablemente puede contener información redundante y no significativa. Con el objetivo de hacer un proceso eficiente y eficaz de clasificación del estado del motor, se hace un proceso de optimización en las características más relevantes para adquirir la información más significativa del sistema. Es por ello que se hace el uso de la técnica de análisis de componentes principales (PCA). En este paso, se comienza con una matriz general, que contiene primeramente los 100 renglones de los tramos de la señal por las 8 columnas de los indicadores característicos, posteriormente se situarán las severidades de falla, es decir, en caso de analizar el motor de inducción con el rodamiento cerámicos o metálico, solo se tienen dos severidades de fallas (1mm y 2mm de diametro), entonces, en la matriz general quedaria de 300 segmentaciones por los 8 indicadores, donde las 100 primeras son del estado sano del

motor, de la 101-200 es de la severidad de falla de 1mm y de la 201-300 corresponde a la severidad de 2mm.

Para la PCA se prosigue calculando la desviación estandar a la matriz general, después se obtiene una matriz de covarianza, la cual resulta ser una matriz cuadrada de 8x8. La super posición se hace analizando los datos de proyección que corresponde a las primeras columnas. Cada valor representa un dato Fisher, se requiere que este valor sea el mas grande porque indica la perarabilidad de los datos, mientras que un valor de Fisher pequeño inica datos tendientes a ser traslapados. Una correcta representación de la PCA es como la Figura 34.

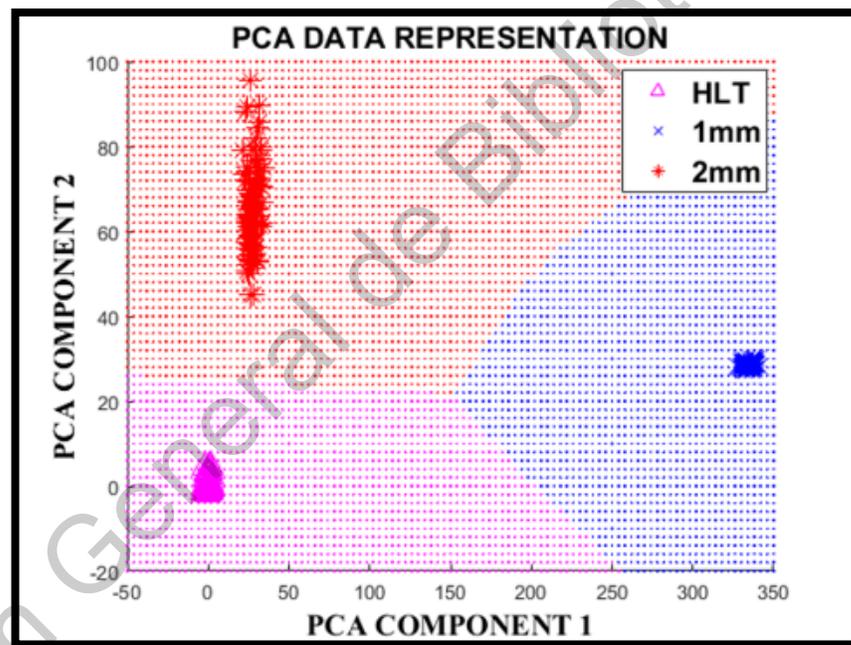


Figura 34. Representación de PCA

### Clasificación

Este ultimo paso de clasificación se realiza bajo la estructura de clasificación de K-vecinos mas cercanos (KNN), este algoritmo entra en el aprendizaje automatico supervisado, lo que quiere decir, que por medio de tarjets se le indicarán datos conocidos para un previo entrenamiento. Para el entrenamiento en este caso se utiliza el 70% de los datos, y el otro 30% se usa para validar la metodologia y las técnicas implementadas. Por lo que, en el 70%

de los datos después de la PCA ya deben de estar en una proyección de tal forma que cada clase se encuentre separada, y dentro del algoritmo KNN se le indicará a que clase pertenece cada punto. Entonces cada que entre un dato del 30% que se usará para validar, este dato calculará las distancias euclidianas de todos los puntos, tomando los 3 mas cercanos a él. Una vez que tenga los tres puntos mas cercanos al dato a clasificar, éste vera de que clase hay mas puntos y por ende, se clasificará con la mayoría.

Por jemplo, supón que los datos de color verde azul y rojo de la Figura 35 son los datos de entrenamiento de la matriz de PCA que contiene los datos sano ( $w_1$ ), falla de 1mm ( $w_2$ ), falla de 2mm ( $w_3$ ) y se va a clasificar el primer punto ( $X$ ) del 30% de los datos de validación. Dependiendo del valor que se le de a  $K$ , el dato  $X$  tomará los  $K$  puntos mas cercanos y se clasificará en la clase que contenga mas puntos. En el ejemplo se clasificaria con el estado sano por estar cerca de 4 puntos de esta clase, a diferencia de solo 1 punto de la clase con falla de 2mm.

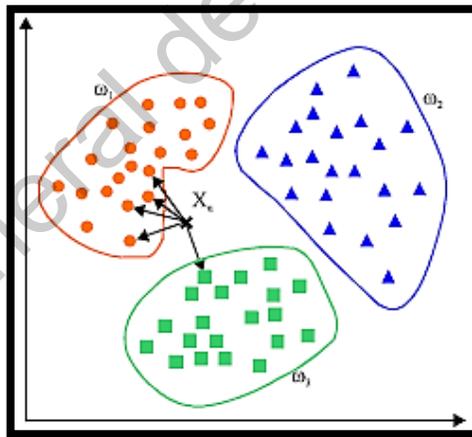


Figura 35. Algoritmo KNN

# CAPÍTULO IV

## 4. RESULTADOS Y DISCUSIONES

En este capítulo se presentan los resultados obtenidos de la metodología descrita en el capítulo anterior, tomando en cuenta las señales adquiridas con las condiciones consideradas del banco de pruebas ya mencionado. Se muestran 4 casos de estudio, pero en cada uno de ellos, se lleva a cabo la metodología propuesta, solo cambia la fuente de base de datos o en su defecto una técnica implementada. Pero en si, el proceso es exactamente lo mismo. Cada caso de estudio presentado en este capítulo, contendrá su diagrama a bloques para facilitar su comprensión.

### Primer caso de estudio

Con el fin hacer pruebas para revisar y validar la programación de las técnicas a implementar, se optó por hacer uso de la base de datos en internet Case Western Reserve University Bearing Data Center Website. Se tomaron las señales con una velocidad del motor de 1750 revoluciones por minuto, con una frecuencia de adquisición de 12000 muestras por segundo. Las señales de rodamientos descargadas desde esa base de datos, con las especificaciones antes mencionadas e incluidas para el análisis de este estudio, así como la representación dentro de cada gráfica son las siguientes:

Condición sano	=	Healthy	=	He
Fallo de pista exterior	=	Outer race fault	=	OF
Fallo de pista interior	=	Inner race fault	=	IF
Falla de bola	=	Ball fault	=	BF

Se consideran los siguientes tres severidades de fallo dadas en pulgadas (in) y representadas en cada gráfica como:

0.007 in	=	7
0.014 in	=	14
0.021 in	=	21

Para cada falla antes mencionada, se tiene las 3 diferentes severidades por lo que se usa la siguiente nomenclatura para las siguientes condiciones de estado de fallo del rodamiento:

He	=	Condición de estado sano
BF7	=	Falla de bola con 0.007 in
BF14	=	Falla de bola con 0.014 in
BF21	=	Falla de bola con 0.021 in
IF7	=	Falla en pista interior con 0.007 in
IF14	=	Falla en pista interior con 0.014 in
IF21	=	Falla en pista interior con 0.021 in
OF7	=	Falla en pista exterior con 0.007 in
OF14	=	Falla en pista exterior con 0.014 in
OF21	=	Falla en pista exterior con 0.021 in

Al descargar los datos anteriores, de la página de internet Case Western Reserve University Bearing Data Center Website, algunas señales eran mas grandes que otras, asi que, al tener 12kHz, se propuso tomar 10 segundos de cada señal, por lo que se tiene un vector de 120000 muestras. En la Figura 36 se muestra el diagrama a bloques de la metodología antes mencionada, comenzando desde la base de datos y siguiendo con hacer el

proceso de segmentación, para cada tramo de la señal se toman 3000 muestras, dado esto, para cada señal analizada se tiene una matriz de 40 segmentaciones por 3000 muestras. Posterior a este proceso, se tiene los cálculos característicos estadístico-temporales, donde se calculan los 8 mencionados en la metodología, al termino de este proceso se tiene para cada señal de condición analizada una matriz de 40 segmentaciones por los 8 indicadores, después se realiza la técnica PCA para reducir la dimensionalidad de dicha matriz y poder clasificar teniendo en cuenta 30 datos para entrenamienon de cada señal analizada y 10 datos para validar cada punto con el algoritmo de K vecinos mas cercanos.

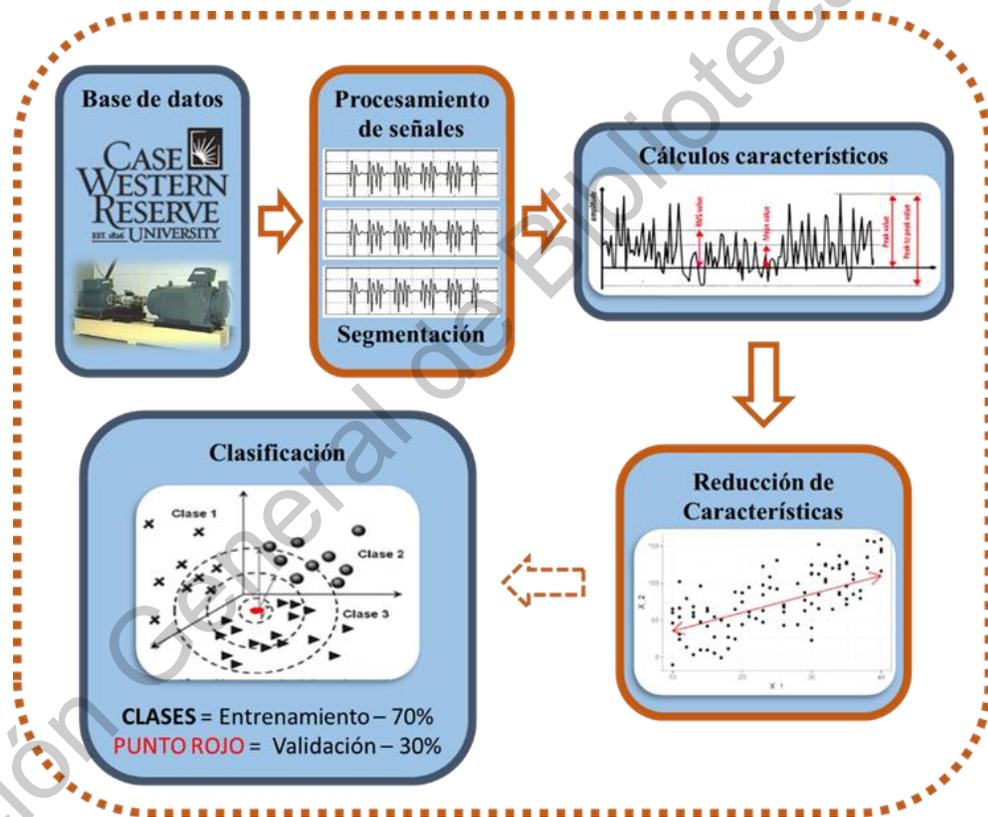


Figura 36. Diagrama a bloques del proceso del caso 1

La Tabla 5 muestra en para cada caso la columna de entrenamiento que son los datos con los que se entrena en algoritro KNN y en la columna de validación muestra los datos que se arrojarán para clasificar. Notece que en el primer caso, el algoritmo solo se entrena con dos señales, que es el estado sano y la falla de bola con una severidad de 0.014 in, pero al validar, se estan arrojando datos con los que no está entrenado el algoritmo de

clasificación. Si que es verdad, que las señales de falla en la columna de validación son las mismas que en la falla de entrenamiento pero con diferente severidad. La cuestión es que probablemente el algoritmo de clasificación realice su trabajo en los datos que ya conoce, pero no se sabe cual sera su decisión al presentarse datos de la misma falla pero con diferente severidad (datos en validación de color rojo).

Tabla 5. Datos de entrenamiento vs datos de validación

Caso	Entrenamiento	Validación
I	He, BF14	He, <b>BF7</b> , BF14, <b>BF21</b>
II	He, BF7, BF14, BF21, IF14	He, BF7, BF14, BF21, <b>IF7</b> , IF14, <b>IF21</b>
III	He, BF7, BF14, BF21, IF7, IF14, IF21, OF14	He, BF7, BF14, BF21, IF7, IF14, IF21, <b>OF7</b> , OF14, <b>OF21</b>

En la Figura 37. Caso I. a) Datos de entrenamiento, b) Datos de validación se tiene el resultado del procesamiento del caso I se muestra en el a) los datos de entrenamiento según la Tabla 5 corresponde a datos de estado sano y solo una falla de bola con una severidad de 0.014 in, a la hora de clasificar los datos de validación en el b) las dos clases que no fueron tomadas en cuenta en el entrenamiento del algoritmo (falla de bola con severidades de 0.007 y 0.021) se clasificaron correctamente (clasificada en la zona de fallo).

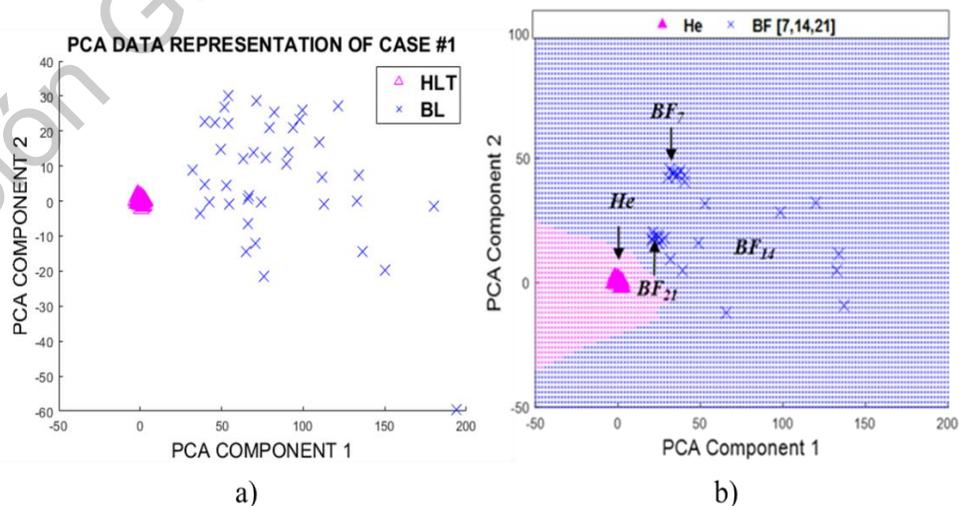


Figura 37. Caso I. a) Datos de entrenamiento, b) Datos de validación

El resultado de lo anterior se muestra en la Tabla 6. Matriz de confusión caso I que representa la matriz de confusión, la matriz de confusión compara el resultado de los datos clasificados contra la clase de los datos que se arrojaron, es decir, lo deseado con lo real. Por lo que en este caso se tiene una clasificación 100% certera.

Tabla 6. Matriz de confusión caso I

Clase	DATOS CONOCIDOS		DESCONOCIDOS
	He	BF 14	BF [7, 21]
He	10	0	0
BF	0	10	20

El en caso II se tiene una situación similar al caso anterior, a diferencia que en este caso se entrena con datos en estado sano, las tres severidades de la falla de bola pero solo con una severidad de falla en pista interior que es de 0.014 in, esto se muestra en la primer gráfica que corresponde a la PCA. En la gráfica de clasificación de la Figura 38, la validación de las fallas en la bola del rodamiento se han clasificado correctamente porque el algoritmo KNN se entreno con todos los datos de cada severidad, pero en la falla de la pista interior solo se ha entrenado con una por lo que la clasificación de la falla de pista interior con severidad de 0.007 in y 0.021 se ha clasificado como falla de bola.

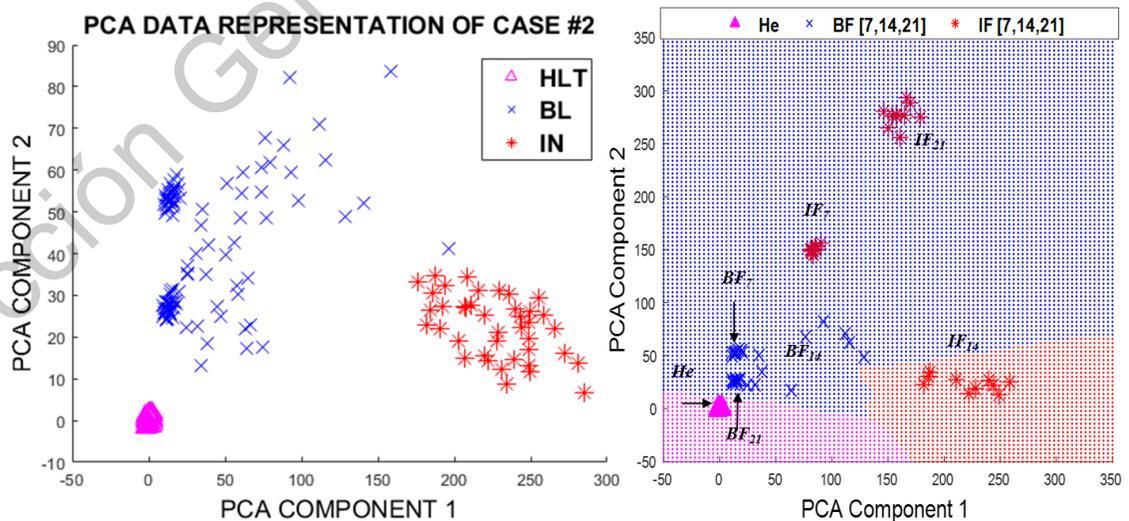


Figura 38. Caso II. a) Datos de entrenamiento, b) Datos de validación

El resultado exacto de la explicación anterior, se muestra en la Tabla 7. La validación se realizó con 10 datos de cada estado, los datos conocidos o lo que es igual, los datos con los que se entrenó el algoritmo KNN se han clasificado correctamente, de los 10 datos de estado sano que se metieron para validar, los 10 se clasificaron en este estado.

De los 10 datos de fallo de bola de cada severidad, los 30 se clasificaron como falla de bola. El problema se tiene cuando se arrojan datos desconocidos, por ejemplo, solo se metieron a entrenamiento 10 datos de falla de pista interna con severidad de 0.014 in y al validar con datos de la misma falla de pista interna pero con diferente severidad, estos dos últimos se clasificaron como falla de bola.

**Tabla 7. Matriz de confusión caso II**

Clases	DATOS CONOCIDOS			DESCONOCIDOS
	He	BF[7,14,21]	IF 14	IF [7, 21]
He	10	0	0	0
BF	0	30	0	20
IF	0	0	10	0

Para finalizar con este caso de estudio 1, se tiene la Figura 39 con el último caso III de la Tabla 5. para entrenamiento primeramente se meten datos de estado sano, posteriormente se meten datos de fallo de bola en las tres severidades, después se meten datos de fallo en pista interna igualmente en las tres severidades, y finalmente se meten datos de fallo en la pista exterior solo de una severidad.

Por lo que, al hacer la validación en el algoritmo KNN, de simple vista se alcanza a distinguir que los datos no conocidos que pertenecen a fallos en la pista externa y representados con estrellas negras, dichos datos son clasificados como fallas en la pista interior.

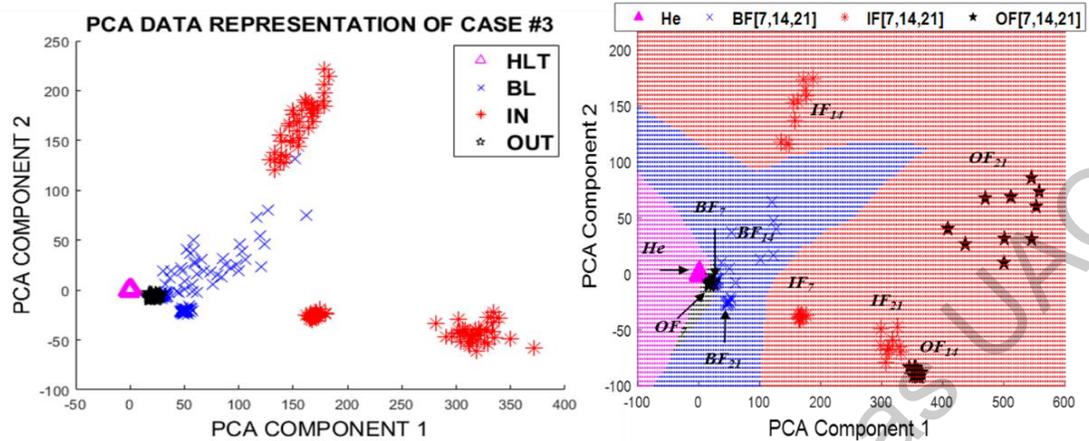


Figura 39. Caso III. a) Datos de entrenamiento, b) Datos de validación

En la Tabla 8 se muestra la matriz de confusión del caso de estudio III, donde, al igual que en los casos anteriores, la validación se lleva a cabo con 10 datos de cada condición de estado. Al validar el estado sano, los diez datos son clasificados correctamente. Al validar los datos de fallo en bola, el único problema se tubo solo en la severidad de 0.007 in, ya que 8 de ellos fueron clasificados en falla de bola, pero los otros dos se han clasificado en falla de la pista exterior, con respecto a las otras dos severidades de falla de bola, los 20 datos se clasificaron correctamente. En la validación de falla de pista interior no se conto con ninguna dato clasificado incorrectamente, lo que es normal ya que al entrenar el algoritmo, se tomaron en cuenta todos los datos. Como es costumbre, el problema mayor se tiene al clasificar los datos con los que no se ha entrenado el algoritmo KNN, ya que incluso un dato fue erroneamente clasificado aunque con esa severidad si se haya entrenado. Pero los 20 datos de las 2 severidades nuevas desconocidas fueron clasificados en el fallo de pista interior.

Tabla 8. Matriz de confusión caso III

Clases	DATOS CONOCIDOS				DESCONOCIDOS		
	He	BF 7	BF 14	BF 21	IF [7,14,21]	OF 14	OF [7, 21]
He	10	0	0	0	0	0	0
BF	0	8	10	10	0	1	0
IF	0	0	0	0	30	0	20
OF	0	2	0	0	0	9	0

## Segundo caso de estudio

Después de validar las técnicas en el primer caso de estudio, con una base de datos ampliamente utilizada por la mayoría de los ingenieros y científicos que se dedican al estudio de fallas en rodamientos de motores de inducción, se propone proceder a fabricar las fallas para analizar y comparar las señales de rodamientos metálicos y cerámicos. La severidad de las fallas fueron seleccionadas después de haber revisado artículos donde analizan fallas fabricadas propiamente.

En la Figura 40 se muestra el diagrama del proceso completo utilizado para el análisis de los rodamientos tanto metálicos como cerámicos. Primero se fabricaron las fallas en la pista interior de los rodamientos, después se capturó una base de datos de ambos rodamientos con cada condición fabricada y de estado sano a diferentes frecuencias, finalmente al tener la base de datos en la PXI se pasa a la computadora personal donde se hace el procesamiento anterior para el análisis de señales.

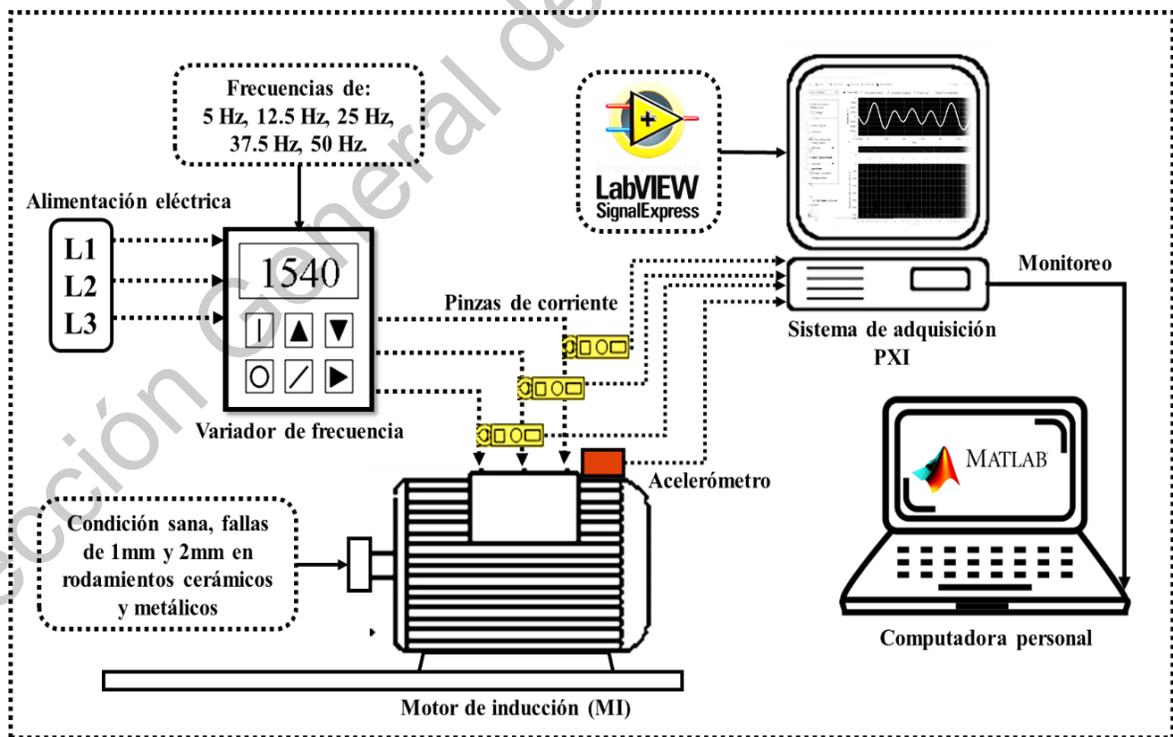


Figura 40. Diagrama de proceso del análisis de fallas en rodamientos metálicos y cerámicos

### Fabricación de fallas

Las fallas de los rodamientos metálicos y cerámicos fueron fabricadas con brocas de 1mm y 2mm, las fallas fueron situadas para el análisis en la pista interior, por lo que los rodamientos fueron desarmados, como se muestra en la Figura 41. El modelo del rodamiento metálico es 6205-ETN9/C3 mientras que el modelo del rodamiento cerámico es el 6205-CE-ZRO2-ZEN.



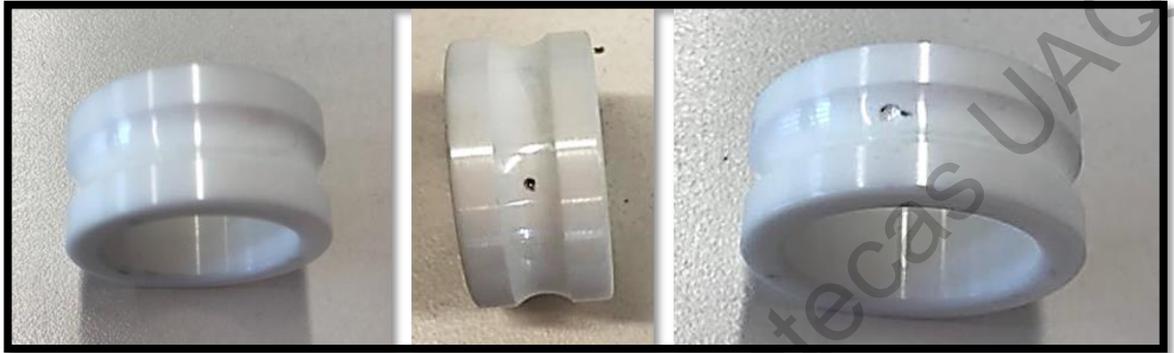
Figura 41. Fabricación de fallas en rodamientos

Se muestra en la Figura 42 la pista interior del rodamiento metálico en estado sano, posteriormente se presenta en la misma pista interior la falla con 1mm de diámetro y finalmente la falla con 2mm de diámetro.



Figura 42. Estados de fallas en rodamientos metálicos

En la Figura 43 se muestra la pista interior del rodamiento cerámico en estado sano, posteriormente se muestra la misma pista interior con un diámetro de falla de 1mm y finalmente se muestra la falla de 2mm de diámetro.



**Figura 43. Estado de fallas en rodamientos cerámicos**

Para la base de datos se usa una nomenclatura específica ya que se adquirieron señales en cada uno de estos rodamientos y a diferentes velocidades de giro del motor. Con diferentes velocidades de giro, se hace referencia a que la base de datos cuenta con 5 velocidades de giro diferente para cada rodamiento, la Tabla 9. Velocidades del motor muestra la equivalencia entre frecuencia de alimentación del motor, el porcentaje de velocidad y las revoluciones por minuto ideales para dicha alimentación.

**Tabla 9. Velocidades del motor**

<b>Frecuencia de alimentación (Hz)</b>	<b>Porcentaje de velocidad (%)</b>	<b>Revoluciones por minuto (RPM)</b>
<b>50</b>	<b>100</b>	<b>3000</b>
<b>37.5</b>	<b>75</b>	<b>2250</b>
<b>25</b>	<b>50</b>	<b>1500</b>
<b>12.5</b>	<b>25</b>	<b>750</b>
<b>5</b>	<b>10</b>	<b>300</b>

Teniendo en cuenta que se tomaron datos de vibración y corriente, la nomenclatura comienza con esta letra, es decir:

**Primer dato:** indica con una (V) si la señal se trata de vibración y con una (I) si se trata de corriente.

**Segundo dato:** pertenece al estado del rodamiento, si está en estado sano tiene como segundo dato una (S) y si es una condición de fallo tiene una (F).

**Tercer dato:** el diámetro de la falla, tiene un (1) si la severidad de falla pertenece a 1mm y un (2) si la falla tiene un diámetro de 2mm, si el rodamiento se encuentra en estado sano, entonces el segundo dato tendrá una (S) y no tendrá este tercer dato.

**Cuarto dato:** número de bolas, aunque en esta tesis solo se analizan los rodamientos de 9 bolas, también se adquirieron datos de un rodamiento metálico con 8 bolas, por lo cual este dato solo contiene un (8) o un (9).

**Quinto dato:** tipo de rodamiento, si es metálico tiene una (M) y si es cerámico tiene una (C).

**Sexto dato:** todos contienen un guion bajo (\_) y después la frecuencia de alimentación para la velocidad del motor, si la frecuencia es de 50Hz entonces este sexto dato lucirá así (\_50) si la frecuencia es de 37.5Hz entonces lucida así (\_37\_5).

**Séptimo dato:** no todas las señales contienen este último dato, ya que este corresponde a las veces que se tomó la misma señal, es decir, solo puede contener de 2 en adelante (\_2), e indicará la segunda adquisición de las especificaciones anteriores.

Un ejemplo de lo anterior para aclarar la nomenclatura es lo siguiente:

**VF29M\_12\_5.txt**

Hace referencia que se trata de una señal de vibración, con falla de 2mm de severidad y es un de un rodamiento metálico de 9 bolas y la frecuencia de velocidad que contenía el motor a la hora de esa adquisición fue de 12.5 Hz. En caso de que se realizará una segunda adquisición con exactamente los mismos datos anteriores, entonces la nomenclatura contendrá un dato extra que será (\_2) como se muestra en la siguiente nomenclatura y así sucesivamente.

## VF29M\_12\_5\_2.txt

Como se mencionó anteriormente, los rodamientos de prueba fueron montados en el lado del ventilador del motor, y con el fin de que cada una de las adquisiciones se realizarán en la misma condición pensando en el análisis de señales, se marcaron las pistas interiores de los rodamientos donde se encontraba la falla fabricada, y se optó por situarlas a las 12:00 en punto como se muestra en la primera flecha roja de la Figura 44.



Figura 44. Montaje de rodamiento en el motor con falla a las 12:00

Con las especificaciones anteriores se hizo la adquisición de alrededor de 200 señales. Por el momento, solo se va a presentar un caso que hace la comparativa de ambos rodamientos.

Para este caso de estudio se van a tomar las señales con velocidades de 1500 revoluciones por minuto. Como ya se dijo en la metodología, se están tomando 100 segundos de señal por cada prueba, y cada segundo contiene 5000 muestras. Se hizo en entrenamiento

con 70 datos y la validación con 30.

En la Figura 45 se muestran los resultados del análisis de los rodamientos metálicos, Las gráficas representativas de la PCA que entreno al algoritmo KNN y de la validación con el algoritmo KNN. Por lo que gráficamente se puede observar que no hay tanta complejidad a la hora de clasificar los datos.

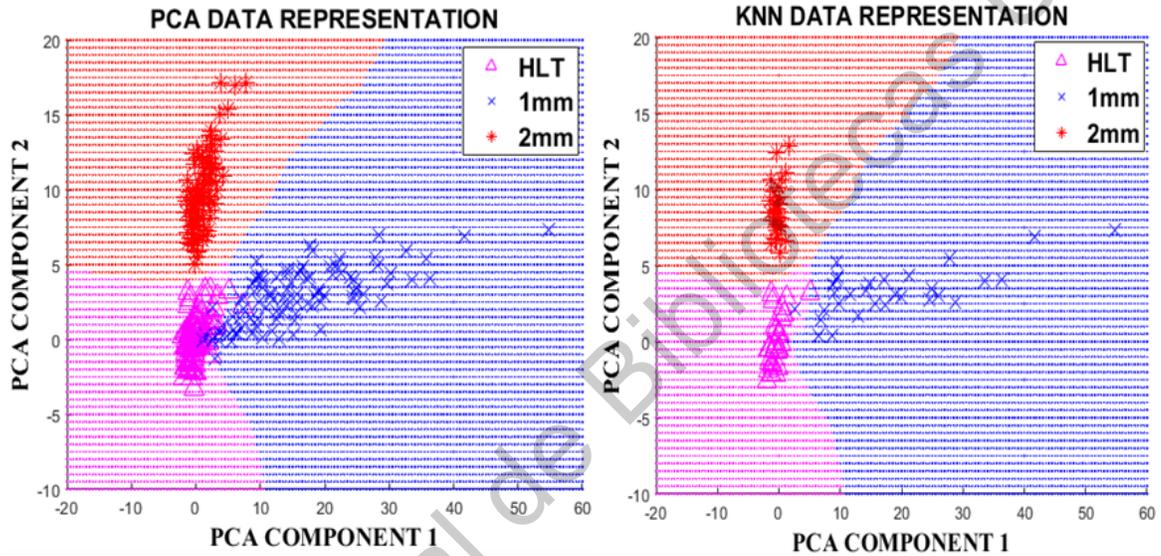


Figura 45. Clasificación en rodamientos metálicos

La matriz de confusión del resultado anterior de los rodamientos metálicos es la Tabla 10 no tiene una clasificación perfecta, ya que se ha equivocado en dos valores de 90 que realizo.

Tabla 10. Matriz de confusión de rodamientos metálicos

	<i>HLT</i>	<i>1MM</i>	<i>2MM</i>
<i>HLT</i>	29	1	0
<i>1mm</i>	1	29	0
<i>2mm</i>	0	0	30

El siguiente análisis es exactamente el mismo que los anteriores pero ahora aplicado en los rodamientos ceramicos, con las mismas especificaciones de velocidad a 25 Hz dando

1500 revoluciones por minuto, se aplica la metodología a señales solo de vibración a rodamientos ceramicos, por lo que se tienen 100 segmentaciones de cada severidad, se procede a calcular los indicadores característicos, después la PCA y finalmente se entrena el algoritmo KNN con 70 datos y se valida el entrenamiento con 30. La Figura 46 muestra las gráficas del resultado del análisis descrito. Por lo que gráficamente es notable que la clasificación no logra ser del todo clara, ya que los datos suelen traslaparse bastante.

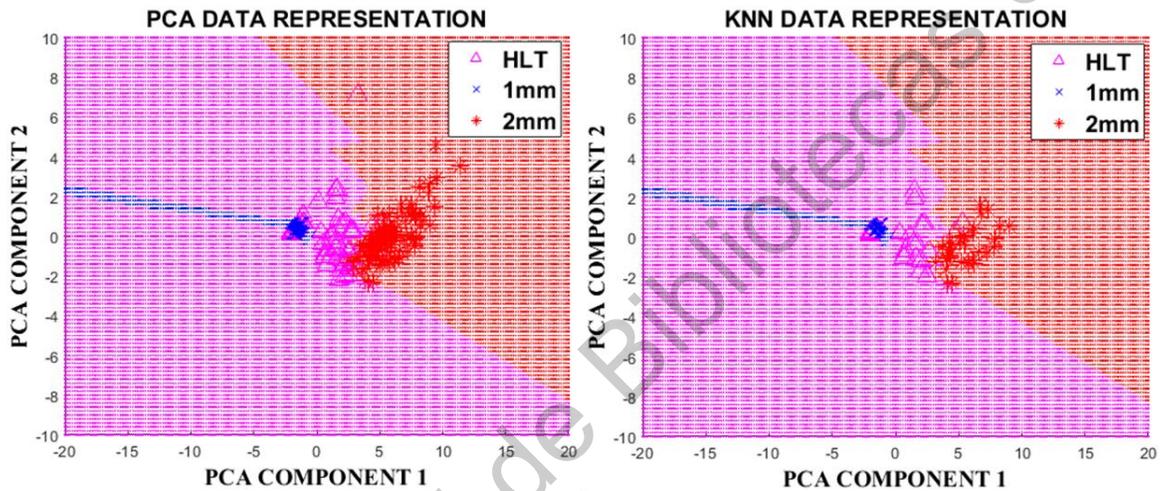


Figura 46. Clasificación en rodamientos ceramicos

La matriz de confusión de este análisis se muestra en la Tabla 11. A pesar de que los rodamientos estén bajo las mismas condiciones, en el mismo motor y situados en el mismo sitio. A la hora de procesar las señales, los rodamientos ceramicos no tienen buena clasificación, ya que, de 90 datos para validar, solo clasificó correctamente 56 datos.

Tabla 11. Matriz de confusión de rodamientos ceramicos

	<i>HLT</i>	<i>1MM</i>	<i>2MM</i>
<i>HLT</i>	19	14	9
<i>1mm</i>	8	16	0
<i>2mm</i>	3	0	21

### Tercer caso de estudio

En el tercer caso de estudio, se hace el análisis de las técnicas tiempo frecuencia, aquí se le anexa un paso más a la metodología, de tal forma que, se toma la señal y se le realiza la segmentación, pero antes de calcular los indicadores característicos como normalmente se venía haciendo, se aplica la técnica de descomposición de modo empírico. Esta técnica tiempo-frecuencia calcula funciones de modo intrínseco (IMF) que implican descomponer la señal en algunas otras señales significativas. Al hacer ese procesamiento en matlab, la función en algunos casos da como resultado más IMF que en otros casos. Por ende se optó por considerar las 8 IMF más significativas.

Retomando la metodología anterior se tendría la matriz general como las 300 segmentaciones por las 8 IMF y a esta matriz se le calculan los indicadores característicos, por lo que el resultado debe dar una matriz de 300 tramos por 64 indicadores. Después se procede con hacer la reducción de dimensionalidad y finalmente con clasificar los datos.

La figura 47 muestra los resultados del procesamiento con técnicas tiempo-frecuencia. Notece que la clasificación es perfecta. De hecho, la PCA con la que se ha entrenado el algoritmo KNN está completamente separada. Los datos de validación gráficamente están muy aislados, lo que representan mejores resultados que los anteriores.

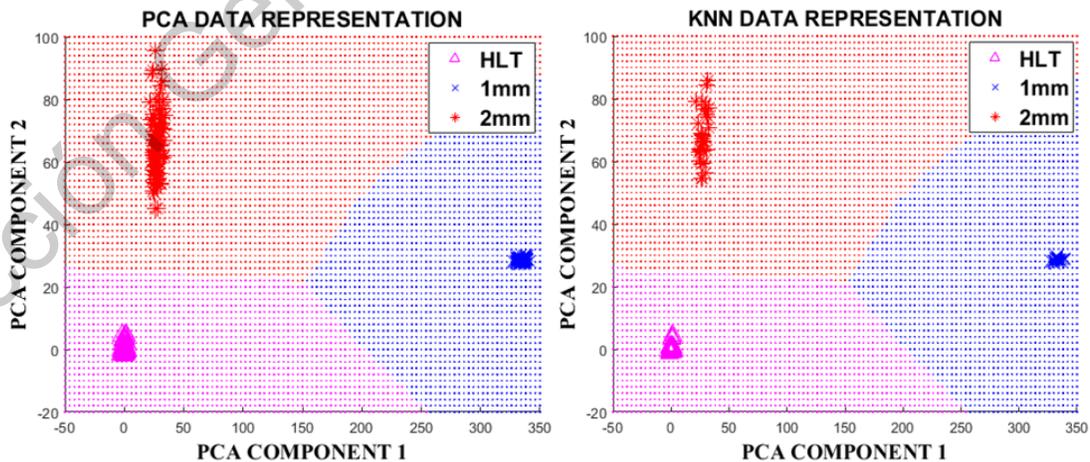


Figura 47. Resultado de rodamientos metálicos con técnica tiempo-frecuencia

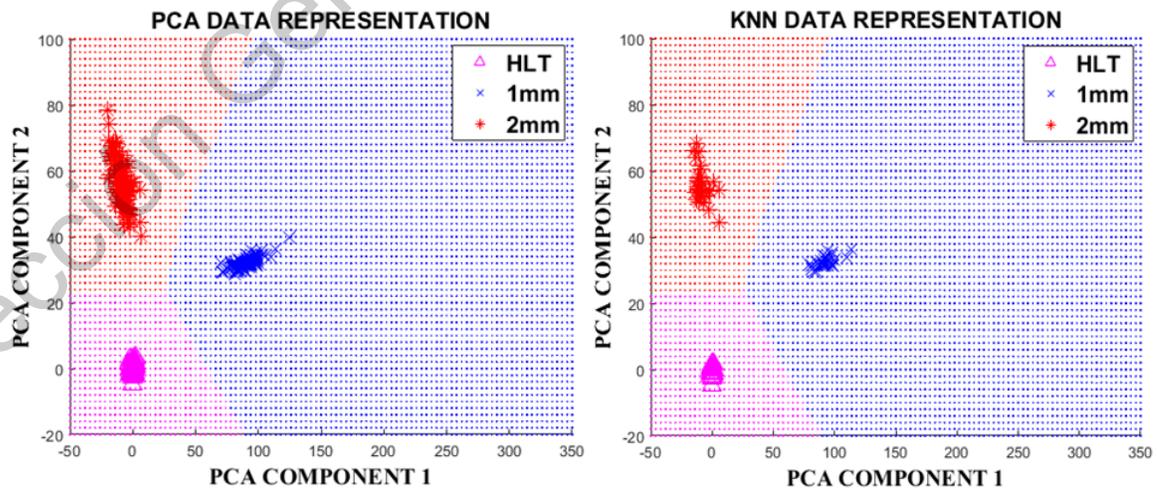
La Tabla 12 confirma lo que gráficamente muestra la figura anterior, lo que es

congruente, ya que al ser procesado los datos con técnicas tiempo frecuencia, estas dan más información a solo hacer el procesamiento con técnicas de tiempo. Es así que, de 30 datos para validación de estado sano, los 30 se clasificaron como sanos, de los 30 dato de validación de las fallas con cada severidad los 30 de cada falla fueron clasificados correctamente.

**Tabla 12. Matriz de confusión del análisis tiempo-frecuencia de rodamientos metálicos**

	<i>HLT</i>	<i>1mm</i>	<i>2mm</i>
<i>HLT</i>	30	0	0
<i>1mm</i>	0	30	0
<i>2mm</i>	0	0	30

Ahora bien, el problema más grande de clasificación en el caso anterior fue en los rodamientos cerámicos, en los rodamientos metálicos solo tuvieron 2 fallas de 90 datos que se metieron a validar, pero en los rodamientos cerámicos de 90 datos que se validaron, 56 datos fueron erróneos. Exactamente las mismas señales analizadas en el caso anterior se le aplico la técnica tiempo-frecuencia y la figura 48 muestra el resultado se los datos cerámicos. A pesar que no tiene la misma separabilidad que en los rodamientos metálicos, los resultados son perfectos, de los 90 datos de validación, 90 fueron clasificados correctamente.



**Figura 48. Figura 47. Resultado de rodamientos cerámicos con técnica tiempo-frecuencia**

En la matriz de confusión (Tabla 13) es de esperarse que los 30 datos de cada estado del motor estén clasificados correctamente, y efectivamente así lo es. entonces este caso se concluye comprobando que las técnicas tiempo frecuencia proporcionan información adicional a la hora de analizar los datos.

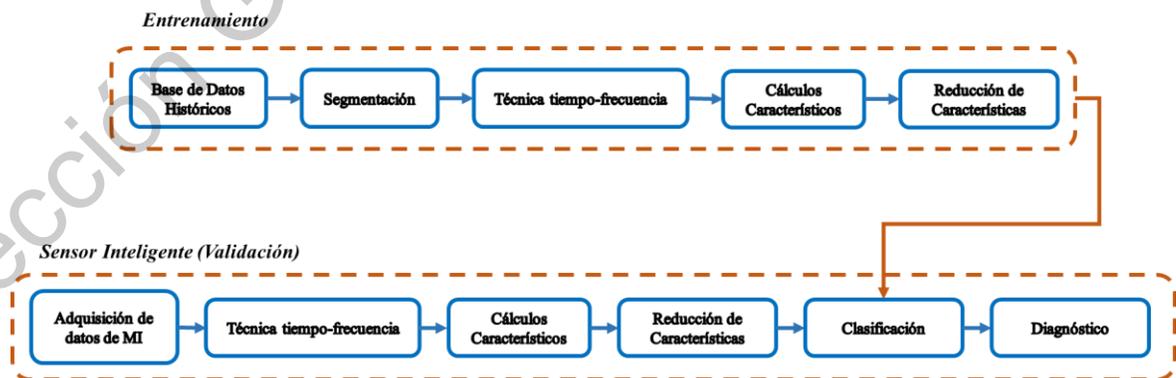
**Tabla 13. Matriz de confusión del análisis tiempo-frecuencia de rodamientos cerámicos**

	<i>HLT</i>	<i>1mm</i>	<i>2mm</i>
<i>HLT</i>	30	0	0
<i>1mm</i>	0	30	0
<i>2mm</i>	0	0	30

#### Cuarto caso de estudio

Este es el último caso de estudio, y lo que propone es un sensor inteligente basado en las técnicas antes mencionadas. La Figura 49 muestra un diagrama esquemático del sensor propuesto.

La parte del entrenamiento se puede hacer fuera de línea para que en programa consuma menos recursos, y el tiempo computacional será relativamente más rápido. Primero dentro del sensor inteligente estará desarrollado en la plataforma Arduino.



**Figura 49. Diagrama esquemático del sensor inteligente propuesto**

En primera estancia se tiene la adquisición de datos que se hace con un acelerómetro

triaxial, directamente se hace la adquisición de datos de 5000 muestras, por lo que, dentro del sensor, el paso de segmentación estaría descartado. De ese tramo de señal se le hace el cálculo de la EMD también solo tomando 8 señales a las cuales posteriormente se le calcularán los indicadores característicos y después se hace la reducción característica que va a transformar de 64 datos a solo dos más importantes que serán clasificados para finalmente poder dar un diagnóstico.

Dirección General de Bibliotecas UAG

# CAPÍTULO V

## 5. CONCLUSIONES

En el primer caso de estudio donde se utilizó la base de datos Case Western Reserve University Bearing Data Center Website, se tiene un análisis completo de varias severidades con una sola señal de adquisición que corresponde a vibración, a pesar de que las severidades no diferían mucho en el tamaño, no tuvieron tanto problema al ser clasificadas, ya que la base de datos es de rodamientos metálicos, que al generar un poco más de fricción que los rodamientos cerámicos, estos tienen características más puntuales a la hora de analizar las señales.

Según los resultados del primer caso, donde el clasificador categoriza sin problemas los datos conocidos, es decir, los datos con los que, si se entrenó el algoritmo de clasificación KNN, pero al clasificar los datos no conocidos, es decir, los datos de validación, no tiene el mismo resultado, aunque la falla sea la misma con diferente severidad. Esto es un problema real pero no drástico en este estudio, ya que el objetivo es crear un sensor inteligente que detente fallas en rodamientos antes de una situación catastrófica, y según los resultados, en cualquier caso, el clasificador categorizaba un tipo de falla en otra diferente pero nunca categorizo una de las fallas en el estado sano. Por lo que, al momento de que cualquier severidad de cualquier falla en el rodamiento metálico o cerámico se presente, el sensor será capaz de indicar una anomalía previniendo así lo indeseado en la maquinaria.

En el segundo caso, ya utilizando la base de datos propiamente adquiridos en el motor de inducción con los rodamientos metálicos y cerámicos en condiciones de estado sano, falla con 1mm y 2mm de diámetro, se demuestra que, al tratar de implementar la misma metodología con una sola señal a la adquisición de rodamientos metálicos y cerámicos, las clasificaciones en las clases fueron traslapadas, este fenómeno fue siempre drástico en el rodamiento cerámico que en el rodamiento metálico ya que por alguna razón la vibración de

las diferentes severidades e incluso la del sano, fueron similares. Por lo que es conveniente hacer uso de las técnicas tiempo-frecuencia por las propiedades que estas ofrecen.

Es por ello que en el caso 3 las mismas señales utilizadas en el caso 2 son sometidas a una metodología donde antes después de aplicar la segmentación de la señal, a cada tramo se le aplica la técnica tiempo-frecuencia EMD donde se limita solo a 8 señales IMF y a cada señal por separado es donde se le calculan los indicadores característicos, por lo que la información de cada tramo es mucho mayor a solo tener los indicadores. Al reducir la dimensionalidad y clasificar estos mismos datos en este caso de estudio, se tiene como resultado una clasificación perfecta, pues ya que de los 90 datos en ambos casos fueron clasificados correctamente los 90.

Por lo que en el cuarto se muestra la metodología propuesta para concluir el sensor inteligente con las mejores técnicas encontradas según el procesamiento ya hecho fuera de línea. La finalidad de este proyecto es hacer la detección de anomalías en los rodamientos tanto metálicos como cerámicos mediante un sensor inteligente previniendo así el mantenimiento correctivo, y así mismo poder hacer la comparativa entre las respuestas de las señales de rodamientos metálicos y la respuesta de las señales cerámicos, por lo que el proyecto está cumpliendo con lo deseado.

# CAPÍTULO VI

## 6. REFERENCIA BIBLIOGRÁFICA

- Acosta-Cervantes, M. C., Villarreal-Marroquín, M. G., & Cabrera-Ríos, M. 2013. Estudio de validación de un método para seleccionar técnicas de pronóstico de series de tiempo mediante redes neuronales artificiales. *Ingeniería, investigación y tecnología*, 14(1), 53-63.
- Blanco-Ortega. 2010. Control de Vibraciones en Maquinaria Rotatoria. *Revista Iberoamericana de Automática e Informática industrial*, vol. 7, no. 4, pp. 36-43.
- BERNAL, J. D. 1979. *La ciencia en la historia*. México, D.F., Editorial Nueva Imagen, vol. 1, 4ta. Edición.
- Chandra, N. H., & Sekhar, A. S. 2016. Fault detection in rotor bearing systems using time frequency techniques. *Mechanical Systems and Signal Processing*, 72, 105-133.
- Chen, Y., Peng, Z., Cheng, Z., & Tian, L. 2017. Seismic signal time-frequency analysis based on multi-directional window using greedy strategy. *Journal of Applied Geophysics*, 143, 116-128.
- Costa-Castelló, R., Ramos, G. A., & Olm, J. M. 2012. Control repetitivo digital de sistemas con frecuencia incierta o variante en el tiempo. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 9(3), 219-230.
- Creus. A. 2010. *Instrumentación Industrial*. ISBN: 978-84-267-1668-2, edición en español publicada por MARCOMBO, S.A., Barcelona, España.: Octava edición: Alfaomega

Grupo Editor, México.

De Angelo, C. H., Bossio, G. R., Giaccone, S. J., Solsona, J. A., Valla, M. I., & García, G. O. 2007. Una estrategia basada en modelos para el diagnóstico de fallas en el estator del motor de inducción. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 4(3), 107-115.

Garcia-Perez, A., Romero-Troncoso, R. J., Cabal-Yepez, E. and Osornio-Ríos, R. A. 2011. The application of high-resolution spectral analysis for identifying multiple combined faults in induction motors. *Transactions on industrial Electronics*. Vol. 58, 2002-2011.

Garcia-Ramirez, A. G., Osornio-Ríos, R. A., Granados-Lieberman, D., Garcia-Perez, A., & Romero-Troncoso, R. J. 2012. Smart sensor for online detection of multiple-combined faults in VSD-fed induction motors. *Sensors*, 12(9), 11989-12005.

Guillermo A. Magallán. 2009. Eliminación de Interferencia Armónica para la Detección de Fallas en Motores Eléctricos. *Revista Iberoamericana de Automática e Informática industrial*, vol. 6, no. 2, pp. 89-97.

Iracheta-Cortez, R. 2015. Simulaciones de transitorios electromagnéticos en redes eléctricas con múltiples pasos de integración a través del modelo de línea dependiente de la frecuencia (FD-Line). *Ingeniería, investigación y tecnología*, 16(1), 13-24.

Liang, B., Iwnicki, S., Ball, A., & Young, A. E. 2015. Adaptive noise cancelling and time-frequency techniques for rail surface defect detection. *Mechanical Systems and Signal Processing*, 54, 41-51.

Medrano-Hurtado. 2016. Nueva metodología de diagnóstico de fallas en rodamientos en una máquina síncrona mediante el procesamiento de señales vibroacústicas empleando

análisis de densidad de potencia. Ingeniería Investigación y Tecnología, vol. XVII, no. 1, pp. 73-85.

Millan-Almaraz, J. R., Romero-Troncoso, R. D. J., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Carrillo-Serrano, R. V., Osornio-Rios, R. A., ... & Torres-Pacheco, I. 2010. FPGA-based fused smart sensor for real-time plant-transpiration dynamic estimation. *Sensors*, 10(9), 8316-8331.

Moreno-Tapia, S. V., Vera-Salas, L. A., Osornio-Ríos, R. A., Dominguez-Gonzalez, A., Stiharu, I., & Romero-Troncoso, R. D. J. 2010. A field programmable gate array-based reconfigurable smart-sensor network for wireless monitoring of new generation computer numerically controlled machines. *Sensors*, 10(8), 7263-7286.

Quiceno, A. F. 2009. Análisis tiempo-frecuencia por métodos no paramétricos orientado a la detección de patologías en bioseñales. Universidad Nacional de Colombia. Grupo de Control y Procesamiento Digital de Señales, Tesis de Maestría.

Rodriguez-Donate, C., Morales-Velazquez, L., Osornio-Rios, R. A., Herrera-Ruiz, G., & Romero-Troncoso, R. D. J. 2010. FPGA-based fused smart sensor for dynamic and vibration parameter extraction in industrial robot links. *Sensors*, 10(4), 4114-4129.

Sharma, M., Achuth, P. V., Pachori, R. B., & Gadre, V. M. 2017. A parametrization technique to design joint time–frequency optimized discrete-time biorthogonal wavelet bases. *Signal Processing*, 135, 107-120.

Stanković, L., Mandić, D., Daković, M., & Brajović, M. 2018. Time-frequency decomposition of multivariate multicomponent signals. *Signal Processing*, 142, 468-479.

Tel-A-Train. 1995. MANTENIMIENTO DE RODAMIENTOS Y COJINETES. A Westcott

Company 309 North Market Street, Chattanooga, TN 37405 USA: Edición Especial Sena.

Vera-Salas, L. A., Moreno-Tapia, S. V., Garcia-Perez, A., Romero-Troncoso, R. D. J., Osornio-Rios, R. A., Serroukh, I., & Cabal-Yepez, E. 2011. FPGA-based smart sensor for online displacement measurements using a heterodyne interferometer. *Sensors*, 11(8), 7710-7723.

Villa-Cañas. 2015. Metodología de análisis tiempo-frecuencia para la evaluación automática de la voz de pacientes con enfermedad de Parkinson. Universidad de Antioquia: Departamento de Electrónica y Telecomunicaciones Medellín, Colombia.

Villalobos. 2015. Algoritmo robusto para el diagnóstico de fallas eléctricas en el motor de inducción trifásico.