

**Universidad Autónoma de Querétaro**  
**Facultad de Ingeniería**  
**Maestría en Ciencias Mecatrónica**

**Análisis Estadístico  
de Señales Aplicado a Cadenas Cinemáticas.**

**Tesis**

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

**Presenta:**

**Francisco Arellano Espitia**

**Dirigido por:**

**Dr. René de Jesús Romero Troncoso  
M.C. Juan José Saucedo Dorantes**

**Febrero 2018**



Universidad Autónoma de Querétaro  
 Facultad de Ingeniería  
 Maestría en Ciencias (Mecatrónica)

**ANÁLISIS ESTADÍSTICO DE SEÑALES APLICADO A CADENAS CINEMÁTICAS**

**Tesis**

Que como parte de los requisitos para obtener el Grado de Maestría en Ciencias (Mecatrónica)


**Presenta:**

Francisco Arellano Espitia

**Dirigido por:**

Dr. René de Jesús Romero Troncoso  
 Dr. Miguel Delgado Prieto  
 M.C. Juan José Saucedo Dorantes

Dr. René de Jesús Romero Troncoso  
 Presidente

  
 Firma

M.C. Juan José Saucedo Dorantes  
 Secretario

  
 Firma

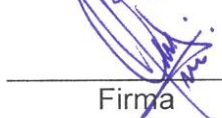
Dr. Miguel Delgado Prieto  
 Vocal

  
 Firma


Dr. Roque Alfredo Osornio Ríos  
 Suplente

  
 Firma

Dr. Miguel Trejo Hernández  
 Suplente

  
 Firma

  
 Dr. Manuel Toledano Ayala  
 Director de la Facultad

  
 Dra. Ma. Guadalupe Flavia Loarca Piña  
 Directora de Investigación y Posgrado

## RESUMEN

En la actualidad, la necesidad de implementar sistemas de monitoreo en maquinaria de la industria moderna es de suma importancia, ya que con la detección oportuna de fallos es posible evitar averías mayores que en consecuencia provocarían paros en la producción y costes elevados. Las exigencias para estos sistemas de monitoreo implican la implementación de diversas técnicas de análisis con la finalidad de hacer un correcto diagnóstico del sistema. Debido a la gran cantidad de elementos que componen una cadena cinemática es posible que se dificulte el correcto análisis del sistema y que en ocasiones se presenten fallos ocultos por otros fallos o por condiciones de operación efectuadas por la maquinaria. Este trabajo presenta un análisis de la capacidad de una metodología de diagnóstico basada en el cálculo de indicadores estadístico-temporales y en la reducción de características de alta dimensionalidad de magnitudes físicas para la detección de múltiples fallos. La metodología propuesta implica la caracterización de una cadena cinemática a través de la adquisición de señales de corriente y vibración, mismas que son sometidas a un proceso de cálculo de indicadores estadístico-temporal y que además de inducirse fallos, la cadena cinemática se opera en condiciones de carga excéntrica. Teniendo en cuenta que los sistemas de monitoreo buscan mejorar la detección de fallos en múltiples condiciones de operación y que estas en ocasiones dificultan la localización de fallos o inclusive llegan a generar falsas alarmas, con la metodología propuesta y en un esquema de fusión de datos se logró una alta capacidad de caracterización del sistema.

(Palabras clave: monitoreo de la condición, cadena cinemática, cálculo de indicadores, corrientes de estator, vibraciones)

## **ABSTRACT**

Nowadays, the need to implement monitoring systems in modern industry machinery is very important, since with the timely detection of faults it is possible to avoid major breakdowns that would consequently cause production stoppages and high costs. The requirements for these monitoring systems involve the implementation of various analysis techniques in order to make a correct diagnosis of the system. Due to the large number of elements that make up a kinematic chain, it is possible that the correct analysis of the system is difficult and that sometimes hidden faults arise due to other faults or operating conditions carried out by the machinery. This project presents an analysis of the capacity of a diagnostic methodology based on the calculation of statistical-temporal features and the reduction of characteristics of high dimensionality of physical magnitudes for the detection of multiple failures. The proposed methodology involves the characterization of a kinematic chain through the acquisition of stator current and vibration signals, which are subjected to a process of calculation of statistical-temporal features and that in addition to inducing faults, the kinematic chain is operated under conditions eccentric loading. Bearing in mind that the monitoring systems seek to improve the detection of faults in multiple operating conditions and that these sometimes make it difficult to locate faults or even generate false alarms, with the proposed methodology and in a data fusion scheme achieved a high capacity for system characterization.

(Keywords: condition monitoring, kinematic chain, feature estimation, stator currents, vibrations)



*A mis padres  
por todo su apoyo y su amor incondicional.*

## **Agradecimientos**

A todas aquellas personas que de alguna manera me han apoyado para la realización de este trabajo, que me han motivado a seguir adelante y que me han guiado y aconsejado de alguna manera a lo largo de mi trayectoria.

A mis padres, Teresita y Francisco por su confianza, por la dedicación que me han brindado y por todas y cada una de sus valiosas enseñanzas.

A mis hermanas, Arely y Diana, por brindarme su apoyo cuando lo he necesitado y por la motivación que siempre me han brindado.

A mis asesores, Dr. René y M.C. Juan José por permitirme trabajar y colaborar en el grupo de investigación HSP-Digital y por todos los conocimientos y enseñanzas recibidas.

Al coordinador de la maestría, Dr. Roque y a todos mis profesores por su dedicación y porque gracias a ellos he logrado crecer en lo académico y profesional.

Al Dr. Miguel y al grupo MCIA, por recibirme y aceptar colaborar durante mi estancia en la Universidad Politécnica de Cataluña, por su paciencia y por todos sus consejos y aprendizajes.

Al Consejo Nacional de Ciencia y Tecnología CONACyT por otorgarme una beca (No. 431363) para poder realizar mis estudios de maestría en la Universidad Autónoma de Querétaro.

A todos mis amigos y compañeros de la universidad, por hacer amena y agradable mi estancia durante estos años.

Gracias.

## TABLA DE CONTENIDOS

<b>1. INTRODUCCIÓN</b> .....	<b>1</b>
1.1 ANTECEDENTES .....	2
1.2 OBJETIVOS E HIPÓTESIS .....	8
1.2.1 OBJETIVO GENERAL .....	8
1.2.2 OBJETIVOS PARTICULARES .....	8
1.2.3 HIPÓTESIS .....	9
1.2 JUSTIFICACIÓN .....	9
<b>2. REVISIÓN DE LA LITERATURA</b> .....	<b>10</b>
2.1 ESTADO DEL ARTE .....	10
2.2 TÉCNICAS DE ANÁLISIS DE INDICADORES ESTADÍSTICOS Y CLASIFICADOR .....	12
2.2.1 ANÁLISIS DISCRIMINANTE LINEAL.....	12
2.2.2 ANÁLISIS DE COMPONENTES PRINCIPALES .....	14
2.2.3 RED NEURONAL ARTIFICIAL .....	16
2.3 FALLAS EN CADENAS CINEMÁTICAS Y CONDICIONES DE OPERACIÓN .....	20
2.3.1 FALLAS EN BARRAS ROTAS .....	20
2.2.2 EXCENTRICIDAD DE CARGA EN EL EJE .....	21
<b>3. METODOLOGIA</b> .....	¡ERROR! MARCADOR NO DEFINIDO.
3.1 BANCO DE PRUEBAS.....	26
3.2 CASOS DE ESTUDIO. ....	¡ERROR! MARCADOR NO DEFINIDO.
3.2.1 MOTOR DE INDUCCIÓN CON BARRAS ROTAS Y EXCENTRICIDAD .....	28
3.3 SISTEMA DE ADQUISICIÓN. ....	29
3.4 PROCESAMIENTO DE SEÑALES. ....	31
3.4.1 SECCIONAMIENTO DE LAS SEÑALES EN TIEMPO.....	32
3.4.2 CALCULO DE CARACTERÍSTICAS ESTADÍSTICO-TEMPORAL.....	33
3.4.3 NORMALIZACIÓN DE LAS CARACTERÍSTICAS ESTADÍSTICO-TEMPORAL.....	39
3.4.4 SELECCIÓN DE CARACTERÍSTICAS SIGNIFICATIVAS .....	39
3.4.5 CLASIFICACIÓN DE LAS CONDICIONES .....	42

<b>4. EXPERIMENTACIÓN Y RESULTADOS.....</b>	<b>45</b>
4.1 VALIDACIÓN DEL ANÁLISIS DE EXTRACCIÓN DE INDICADORES ESTADÍSTICO-TEMPORALES.....	45
4.2 ANÁLISIS ESTADÍSTICO PARA CLASIFICACIÓN DE FALLOS EN BARRAS DE ROTOR.....	50
4.3 IDENTIFICACIÓN DE EXCENTRICIDAD DE MASA .....	<b>¡ERROR! MARCADOR NO DEFINIDO.</b>
4.4 ANÁLISIS ESTADÍSTICO PARA CONDICIONES DE OPERACIÓN CON EXCENTRICIDAD DE MASA .....	56
4.5 ANÁLISIS ESTADÍSTICO PARA DE FALLO EN BARRA ROTA Y CONDICIONES DE OPERACIÓN CON EXCENTRICIDAD DE MASA .....	58
4.6 CLASIFICADOR BASADO EN REDES NEURONALES .....	61
<b>5. CONCLUSIONES .....</b>	<b>67</b>
<b>6. REFERENCIAS.....</b>	<b>69</b>
<b>7. ARTICULOS PUBLICADOS.....</b>	<b>73</b>

## ÍNDICE DE FIGURAS

FIGURA 2.1 PROYECCIÓN DE LAS MUESTRAS EN DOS LINEAS DIFERENTES. A) MUESTRA UNA MENOR SEPARACIÓN ENTRE LOS PUNTOS PROYECTADOS. B) MUESTRA UNA MAYOR SEPARACIÓN ENTRE LOS PUNTOS PROYECTADOS .	13
FIGURA 2.2 ESQUEMA DE NEURONAS. A) NEURONA BIOLÓGICA, B) NEURONA ARTIFICIAL .....	17
FIGURA 2.3 ARQUITECTURA DE UNA RED NEURONAL .....	18
FIGURA 2.4 MOTOR DE INDUCCIÓN CONDUciendo UN TRANSPORTADOR OPERADO A BAJA VELOCIDAD Y ALTO TORQUE .....	22
FIGURA 3.1 METODOLOGÍA PROPUESTA .....	25
FIGURA 3.2 BANCO EXPERIMENTAL.....	27
FIGURA 3.3 A) FALLO EN BARRA ROTA. B) DISCO CON DESBALANCE.....	28
FIGURA 3.4 B) ACCELEROMETRO. B) ENCODER .....	29
FIGURA 3.5 TARJETA DE ACONDICIONAMIENTO CON SENSORES DE CORRIENTE.....	30
FIGURA 3.6 TARJETA DE ADQUISICIÓN FPGA .....	31
FIGURA 3.7 SEGMENTACIÓN EN TRAMOS DE LAS SEÑALES .....	33
FIGURA 3.8 REPRESENTACIÓN DEL OPERADOR DE UNA NEURONA .....	43
FIGURA 3.9 FUNCIÓN DE TRANSFERENCIA SIGMOIDEA .....	44
FIGURA 4.1 SEÑAL DE VIBRACIÓN DE CWRU .....	46
FIGURA 4.2 PROYECCIÓN DE CARACTERÍSTICAS EXTRAÍDAS MEDIANTE PCA CON UNA SEÑAL DE VIBRACIÓN .....	48
FIGURA 4.3 PROYECCIÓN DE CARACTERÍSTICAS EXTRAÍDAS MEDIANTE PCA CON DOS SEÑALES DE VIBRACIÓN ...	49
FIGURA 4.4 ANÁLISIS EN SEÑALES DE CORRIENTE PARA FALLOS EN BARRAS DEL ROTOR. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	51
FIGURA 4.5 ANÁLISIS EN SEÑALES DE VIBRACIÓN PARA FALLOS EN BARRAS DEL ROTOR. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	52
FIGURA 4.6 LOCALIZACIÓN DE CARGA EXCÉNTRICA CON FFT.....	54
FIGURA 4.7 BARRIDO DE LA FRECUENCIA DE FALLO OCASIONADO POR EL AUMENTO DE CARGA MECÁNICA .....	55
FIGURA 4.8 ANÁLISIS EN SEÑALES DE CORRIENTE PARA IDENTIFICACIÓN DE EXCÉNTRICIDAD DE MASA. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	56

FIGURA 4.9 ANÁLISIS EN SEÑALES DE VIBRACIÓN PARA IDENTIFICACIÓN DE EXCÉNTRICIDAD DE MASA. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	57
FIGURA 4.10 PROYECCIONES DE SEÑALES DE CORRIENTE PARA LOS CASOS EN ESTADO SANO, DESBALANCE, MEDIA BARRA ROTA Y UNA BARRA ROTA. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	59
FIGURA 4.11 PROYECCIONES DE SEÑALES DE VIBRACIÓN PARA LOS CASOS EN ESTADO SANO, DESBALANCE, MEDIA BARRA ROTA Y UNA BARRA ROTA. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	60
FIGURA 4.12 PROYECCIONES DE FUSIÓN DE SEÑALES PARA LOS CASOS EN ESTADO SANO, DESBALANCE, MEDIA BARRA ROTA Y UNA BARRA ROTA. A) PROYECCIÓN CON PCA. B) PROYECCIÓN CON LDA.....	61
FIGURA 4.13 PROYECCIONES DE LAS REGIONES RESULTANTES DE LA RED NEURONAL. A) PCA PARA ENTRENAMIENTO. B) PCA PARA PRUEBA .....	62
FIGURA 4.14 PROYECCIONES DE LAS REGIONES RESULTANTES DE LA RED NEURONAL. A) LDA PARA ENTRENAMIENTO. B) LDA PARA PRUEBA .....	63

## ÍNDICE DE TABLAS

TABLA 3.1 MATRIZ DE PRUEBAS.....	32
TABLA 3.2 CARACTERÍSTICAS ESTADÍSTICO - TEMPORAL.....	34
TABLA 4.1 SUBCONJUNTO DE CARACTERÍSTICAS ESTADÍSTICO - TEMPORAL.....	47
TABLA 4.2 RADIOS DE CLASIFICACIÓN OBTENIDOS CON EL CLASIFICADOR .....	49
TABLA 4.3 MATRIZ DE DE CONFUSIÓN RESULTANTE PARA EL ENTRENAMIENTO MEDIANTE PCA .....	64
TABLA 4.4 MATRIZ DE DE CONFUSIÓN PARA ETAPA DE PRUEBA MEDIANTE PCA.....	64
TABLA 4.5 MATRIZ DE DE CONFUSIÓN RESULTANTE PARA EL ENTRENAMIENTO MEDIANTE LDA .....	65
TABLA 4.6 MATRIZ DE DE CONFUSIÓN PARA LA ETAPA DE PRUEBA MEDIANTE LDA.....	65
TABLA 4.7 RADIOS DE CLASIFICACIÓN OBTENIDOS PARA CORRIENTE, VIBRACIÓN Y FUSIÓN DE MAGNITUDES.....	66

---

# Capítulo 1

## Introducción

---

### 1. Introducción

El uso de motores de inducción es de suma importancia para la industria debido a la capacidad de transformación de energía eléctrica a energía mecánica, lo cual lo hace apto para un sinnúmero de aplicaciones. Elementos mecánicos como cajas de engranes, acoplamientos, ejes, bandas, entre otros elementos, trabajan en conjunto con motores de inducción para realizar operaciones giratorias. No obstante, debido al constante trabajo que desempeñan estos elementos y a factores externos y ambientales, la incidencia de fallos puede ocurrir en cualquier momento, provocando averías y destrozos que en consecuencia afectarían la productividad y generarían pérdidas económicas a la industria. En este sentido, han surgido diferentes estrategias de mantenimiento basadas en la condición de la maquinaria. Dichas estrategias constan de un monitoreo de los componentes de la cadena cinemática con el fin de extraer datos que ayuden a la detección oportuna y precisa de fallos. Sin embargo, aunque se han propuesto una gran cantidad de métodos de diagnóstico de fallos basados en la extracción de datos, el objetivo de la mayoría de estos, se limita a la detección de única de falla.

Los retos a afrontar para poder realizar un correcto diagnóstico de fallos en cadenas cinemáticas y maquinaria industrial, contemplan el reconocimien-



to de múltiples causas de fallos y diversas condiciones de operación. Dicha problemática debe atenderse con estrategias que permitan el diagnóstico de fallos que puedan ocultarse con otro tipo de avería o que puedan presentar falsas alarmas debido a condiciones de operación a la que es expuesta la mayoría de la maquinaria. En este sentido, las nuevas estrategias de diagnóstico plantean el uso combinado de magnitudes físicas, así como el procesamiento de dichas señales en el dominio del tiempo, frecuencia y tiempo. Sin embargo, el análisis de indicadores basados en tiempo ha mostrado un alto potencial para la caracterización de la condición de máquinas industriales. El presente trabajo propone una metodología para el diagnóstico de fallos en una cadena cinemática, empleando análisis estadístico y reducción de indicadores, además siendo caracterizada con diferentes estados de operación, sometida con múltiples niveles de carga.

## 1.1. Antecedentes

En la actualidad los sistemas de diagnóstico de fallos proporcionan una mayor seguridad en la vigilancia en maquinaria estratégica, tales como maquinaria industrial, ya que con la detección oportuna de alguna avería es posible reducir el tiempo de inactividad de las máquinas, disminuir los costos de mantenimiento y evitar accidentes que pudieran tener consecuencias devastadoras (Henríquez *et al*, 2014).

Una cadena cinemática se compone de diversos elementos mecánicos (poleas, correas, eje de transmisión o acoplamientos) conectados a un motor, todos ellos susceptibles a distintos tipos de fallas. Por lo tanto, ha sido necesario realizar el diagnóstico de los diferentes tipos de fallas

que se pueden presentar en cada uno de los elementos, para ello se han desarrollado múltiples técnicas de diagnóstico. En la Universidad Autónoma de Querétaro se han realizado diversos trabajos para la detección de fallas en los elementos de una cadena cinemática. Saucedo-Dorantes *et al* (2014) desarrollaron una metodología para el diagnóstico del desgaste en los engranes de las cajas de cambio utilizando un análisis de vibración en conjunto con un modelo basado en el cálculo de las frecuencias características, analizando los defectos en la señal de vibración. Garcia-Ramirez *et al* (2014) propusieron un análisis termográfico para la detección de fallos en los motores de inducción realizando una metodología basada en la segmentación de imágenes termográficas y revisando el impacto de dichos fallos en la cadena cinemática. Saucedo-Dorantes *et al* (2016) presentaron una metodología para la detección de fallas múltiples en los rodamientos de los motores de inducción y en la caja de engranes en una cadena cinemática, dicha metodología se realiza empleando técnicas por vibración y análisis de corrientes, las cuales proporcionan información por medio de la identificación de los componentes espectrales relacionados al fallo. Mejía (2015) realizó un análisis espectral de impedancias para la detección de fallos en motores de inducción considerando cuatro tipos de fallas: desalineamiento, desbalance mecánico, barra rota y balero dañado.

Estos estudios sobre la detección de fallos en cadenas cinemáticas están a la vanguardia de trabajos científicos realizados a nivel internacional. Gaëtan Didier *et al* (2006) presentaron una técnica para el diagnóstico de barras rotas, haciendo un análisis de señales de voltaje y corriente del estator de un motor de inducción y posteriormente un estudio con periodograma de Bartlett lograron evaluar diferentes índices de fallas globales en el espectro

de potencia. Grant H. Müller *et al* (2003) realizaron una metodología para la detección de fallos por barras rotas en motores de inducción en presencia de corriente interbar. E. T. Esfahani (2014) presentó un sistema multisensor para el monitoreo de motores de inducción. Empleando múltiples mediciones (emisión acústica, vibración y corriente) logró distinguir fallas con excentricidad estática y dinámica del entrehierro, daños en rodamientos con múltiples combinaciones. L. Frosini *et al* propuso un enfoque basado en el uso de corriente y eficiencia de motores de inducción como indicadores de fallas en rodamientos, las averías analizadas fueron: la grieta en la carrera exterior, perforación en la carrera exterior, deformación en la junta y la corrosión. Sin embargo, aunque se han realizado numerosas investigaciones para la detección de múltiples fallos en motores de inducción y cadenas cinemáticas en general, la mayoría de los trabajos no consideran variaciones en las condiciones de operación y los efectos que estos producen, a menudo estas de condiciones de operación pueden interferir en el diagnóstico de fallos ya que pueden presentar frecuencias similares a algunas frecuencias características de fallas.

Algunos trabajos realizados sobre condiciones de operación se basan en el estudio de elementos con carga excéntrica o desbalanceada dentro del sistema rotario. S. Rajagopalan *et al* (2007) propone una metodología basada en la transformada wavelet sobre señales de corriente de estator para la detección de excentricidad dinámica en motores de corriente continua sin escobillas operados bajo condiciones de velocidad y carga rápidamente variable. R. J. Romero-Troncoso (2017) realizó un procesamiento multi-nivel para mejorar el análisis basado en FFT para la detección de fallos en los motores de inducción. En dicho trabajo presenta algunas de las limitaciones del análisis

bajo FFT como son la sensibilidad a la baja relación de señal-ruido, la superposición de componentes espectrales, señales no estacionarias y la fuga espectral. J. Kim *et al* hicieron un estudio del espectro de potencia, en donde se informó que en el componente  $2sf_s$ , frecuencia usualmente usada para la detección de fallos en motores de inducción puede presentar falsas alarmas de falla debido a la asimetría en el rotor o a oscilaciones de carga de baja frecuencia. Propusieron además una metodología para la detección de fallos en motores de inducción con inmunidad a falsas.

Las técnicas de pronóstico han atraído un gran interés de la comunidad científica en los últimos años. Los sistemas de pronósticos permite la predicción de fallos en máquinas que resultan en beneficios a los operadores de plantas tales como los tiempos de parada más cortos, mayor fiabilidad de funcionamiento, reducción de costos de operación y de mantenimiento, y un mantenimiento y logística de planificación más eficaz (Shan *et al*, 2015). Los métodos de pronóstico y diagnóstico de fallos se pueden dividir en dos grupos principales, es decir, métodos basados en modelos y métodos basados en datos. Los enfoques basados en modelos utilizan modelos matemáticos para describir, controlar y supervisar máquinas rotativas; que requieren un amplio conocimiento del sistema y la dinámica asociada con él, que en aplicaciones del mundo real es difícil de lograr. Por otro lado, los métodos basados en datos, comúnmente llamados enfoques basados en datos, han sido ampliamente utilizados en el diagnóstico de fallos para predecir y analizar los estados actuales y futuros de las máquinas rotativas (Yin *et al*, 2014). A continuación se presentan algunas de las técnicas basadas en datos para el diagnóstico de fallas.

Entre las técnicas de clasificación se encuentra la Red Neuronal, una Red Neuronal Artificial o también llamada Red Neuronal (*Neural Network, NN*) es un método de procesamiento de información inspirado en sistemas biológicos, representa uno de los modelos matemáticos más utilizados en una amplia gama de campos de aplicación. Está compuesto por una serie de elementos de procesamiento interconectados que trabajan al mismo tiempo para resolver un problema específico. Los sistemas basados en NN para reconocimiento de patrones están configurados para una aplicación específica, como el diagnóstico, a través de un proceso de aprendizaje. La red neuronal representa un algoritmo no lineal, multivariable y no paramétrico (Theodoridis, 2009). Serra *et al* (2012) utilizaron un modelo híbrido de red neuronal difusa mín-máx (Fuzzy Neural Network, FMM) combinada con CART para la detección y diagnóstico de fallas en los rodamientos de motores eléctricos.

El análisis discriminante lineal (Linear Discriminant Analysis, LDA) es comúnmente utilizado como técnica de reducción de dimensionalidad en la etapa de pre-procesamiento para aplicaciones de patrones de clasificación y de aprendizaje automático. El objetivo es proyectar un conjunto de datos en un espacio dimensional inferior con buena clase de separabilidad en orden con el fin de evitar el sobreajuste y también reducir los costes computacionales (Raschka, 2014). Yoshida *et al* (2008) utilizaron la técnica LDA semi-supervisado en conjunto con un método de identificación de subespacio discriminativo basado en la frontera para la identificación de las variables causales de fallas de energía en edificios. Nabilah *et al* (2015) emplearon el análisis LDA para la clasificación de objetos utilizando un sistema de detección de fuerza.

Abdi y Williams (2010) describieron el análisis de componentes principa-

les (Principal Component Analysis, PCA) como una técnica multivariante que analiza una tabla de datos en la que se describen las observaciones de distintas variables dependientes cuantitativas inter-correlacionadas. El objetivo es extraer la información importante de la mesa, para representar a esta como un conjunto de nuevas variables ortogonales denominadas componentes principales, y para visualizar el patrón de similitud de las observaciones y de las variables como los puntos en los mapas. Raschka (2014) afirmó que el principal propósito del análisis PCA es el análisis de datos para identificar patrones y encontrar patrones para reducir las dimensiones del conjunto de datos con una pérdida mínima de información. Jafarian et al (2016) emplearon la técnica PCA para la clasificación y detección de fallas en motores automotrices usando un análisis por vibración para la adquisición de señales. Zhang *et al* (2015) utilizaron el análisis de componentes principales en conjunto de un análisis de vibración para la detección de corrosión por picaduras en las pistas de rodadura en los rodamientos.

La mayoría de las investigaciones asociadas con el diagnóstico de fallos en los elementos de la cadena cinemática que se han realizado hasta ahora no consideran condiciones operativas con cargas excéntricas entre sus elementos de rotación, o bien dicha excentricidad se mantiene constante. Las técnicas tradicionales para la detección de fallos, como el análisis en frecuencia no permite la diferenciación entre un fallo y una excentricidad en la cadena cinemática. En el presente proyecto de investigación se propone realizar una clasificación de fallos y de condición operativa con carga o desbalance en una cadena cinemática haciendo uso de un análisis de extracción de indicadores estadísticos y reducción de indicadores mediante PCA y LDA.

## 1.2. Objetivos e Hipótesis

A continuación se presentan los objetivos que se pretenden cumplir al realizar este trabajo de tesis, así como su respectiva hipótesis y justificación.

### 1.2.1. Objetivo General

El objetivo de esta tesis es realizar un análisis estadístico de diferentes magnitudes físicas para la detección de múltiples fallos en una cadena cinemática que opera bajo la influencia de cargas excéntricas oscilantes.

### 1.2.2. Objetivos Particulares

- Revisar el estado del arte acerca de las técnicas para la reducción de indicadores estadísticos y tener un precedente de lo que se ha logrado hasta ahora en el diagnóstico de fallas haciendo uso de dichos métodos.
- Hacer un estudio sobre los principales elementos que componen una cadena cinemática, revisar cuáles son los fallos más comunes y qué métodos de análisis se han implementado para su detección.
- Desarrollar e implementar metodologías en software de cada las técnicas de análisis de indicadores: LDA y PCA para poder realizar el análisis de reducción de indicadores estadísticos sobre los datos de prueba.
- Realizar las adecuaciones a la cadena cinemática añadiendo los elementos necesarios para tener una carga oscilante y realizando los cambios para permitir el análisis de fallos de barra rota y rodamientos para posteriormente realizar la instrumentación de dicho banco de pruebas.

- Realizar adquisiciones en el banco de pruebas para cada caso de estudio, procesar las señales y realizar el cálculo y extracción de indicadores estadísticos para posteriormente hacer una clasificación y determinar los fallos y condiciones de carga en la cadena cinemática.

### 1.2.3. Hipótesis

Con un análisis pertinente y con el uso de técnicas de análisis de indicadores estadísticos es posible realizar la detección y clasificación de diversas condiciones de fallas en una cadena cinemática sometida a cargas oscilantes.

## 1.3. Justificación

Hasta ahora, el diagnóstico de fallas en los elementos de cadenas cinemáticas se ha limitado a trabajos operados bajo cargas balanceadas. El efecto que provoca una carga de masa excéntrica dentro de los sistemas rotativos ha sido poco abordado en investigaciones. Algunas de las metodologías implementadas hasta ahora muestran que algunas condiciones de operación pueden crear confusión y ser interpretadas como un fallo en el sistema, sin que dicha condición implique una avería.

Este trabajo pretende hacer un análisis de una cadena cinemática funcionando con una carga excéntrica. Haciendo uso de un estudio de indicadores estadísticos se pretende dar solución a la clasificación entre una condición de operación que implica la carga excéntrica y entre múltiples fallos dentro de una cadena cinemática. Con este trabajo se pretende crear las bases para generar nuevas líneas de investigación en donde se contemplen condiciones de operación en trabajos sobre la detección de fallos en cadenas cinemáticas.



---

## Capítulo 2

### Revisión de la Literatura

---

## 2. Revisión de la Literatura

### 2.1. Estado del Arte

En 1824, el físico francés François Arago formuló la existencia de campos magnéticos en rotación, girando manualmente los interruptores de encendido y apagado, más tarde, en 1879, Walter Baily confirmó dicho efecto, dando lugar al primer motor de inducción primitiva. Los primeros motores de inducción de corriente alterna se inventaron independientemente por Galileo Ferraris y Nikola Tesla, en 1885 y en 1887. Mikhail Dolivo-Dobrovolsky inventó el motor de jaula de rotor de inducción en 1889 y el transformador de tres extremidades en 1890. La compañía General Electric (GE) comenzó a desarrollar motores de inducción trifásicos en 1891.

Wilfred Lewis introduce el sistema involuta para el diseño de dientes de engranes, siendo esta la forma más común en dientes de engranes. Un tren de engranajes es un sistema mecánico formado por el montaje de engranajes en un bastidor de manera que los dientes de los engranajes se acoplan. Los dientes de los engranajes están diseñados de tal manera que se asegura que los círculos de paso del acoplamiento de engranes ruedan unos sobre otros sin deslizarse, proporcionando una buena transmisión de la rotación de una mar-

---

cha a otra. La transmisión de rotación por contacto con ruedas dentadas se remonta al mecanismo de Antikythera de Grecia y el carruaje al sur de China.

Un eje de transmisión es un componente mecánico para la transmisión de par de torsión y rotación, por lo general se utiliza para conectar otros componentes de un tren de accionamiento que no puede ser conectado directamente debido a la distancia o para permitir el movimiento relativo entre ellos. El término eje de transmisión, apareció por primera vez a mediados del siglo 19. En 1861 la patente de Storer sobre una máquina de cepillado, se utiliza el término para referirse al eje accionado por correa con la que se acciona la máquina. Otro uso temprano del término se produce en 1861 en patente de Watkins y Bryson para segadora por caballos. Aquí, el término se refiere al eje de la transmisión de potencia entre las ruedas de la máquina para el tren de engranajes que acciona el mecanismo de corte. Crompton utilizó el término para referirse al eje entre la transmisión de sus vehículos con motor de vapor de 1903 y el eje conducido.

La importancia que tienen los elementos que componen una máquina es debido a que gracias a ellos es posible transmitir movimientos lineales o rotacionales. Como se ha visto a lo largo de la historia se han desarrollado diversos elementos para aumentar la eficiencia dentro de las máquinas de producción. Además, también se debe señalar que es de suma importancia el cuidado de los elementos y la necesidad de realizar un diagnóstico oportuno de fallas para con ello evitar consecuencias no deseadas.

## 2.2. Técnicas de Análisis de Indicadores Estadísticos y Clasificador

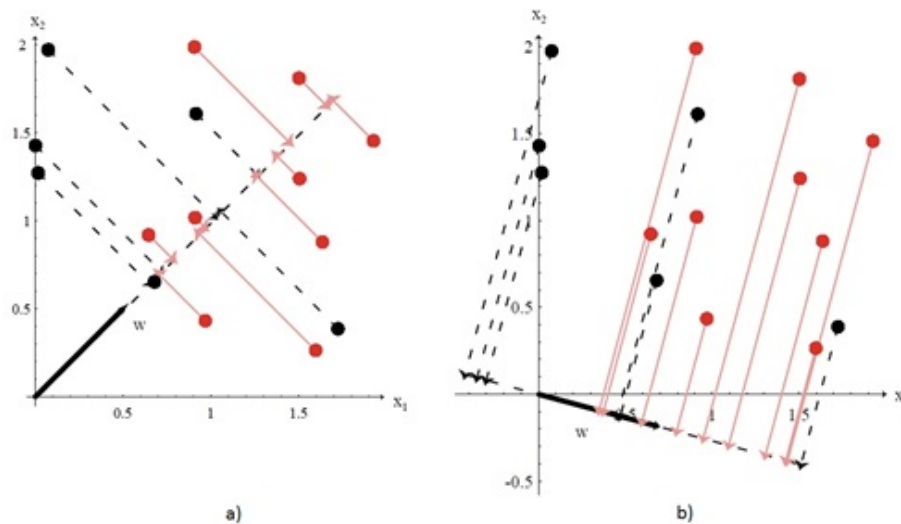
### 2.2.1. Análisis Discriminante Lineal

Uno de los problemas recurrentes en la aplicación de técnicas de indicadores estadísticos a los problemas de reconocimiento de patrones se le ha denominado la "maldición de la dimensionalidad". Los procedimientos que son analítica o computacionalmente manejable en espacios de baja dimensión pueden llegar a ser completamente imprácticos en un espacio de 50 o 100 dimensiones. Por ello, varias técnicas se han desarrollado para reducir la dimensionalidad del espacio de características con la esperanza de obtener un problema más manejable.

Se puede reducir la dimensionalidad desde  $d$  dimensiones a una dimensión si se limita a proyectar los  $d$  datos dimensionales sobre una línea. Por supuesto, incluso si hay una buena separación entre las muestras, grupos compactos en el espacio  $d$ , proyectados sobre una línea arbitraria generarían una mezcla confusa de muestras de todas las clases, y por lo tanto un pobre rendimiento de reconocimiento. Sin embargo, al mover la línea alrededor, podría ser capaz de encontrar una orientación para que las muestras proyectadas están bien separadas. Este es precisamente el objetivo del análisis discriminante clásico. Supóngase que se tiene un conjunto de  $n$  muestras de  $d$  dimensiones  $x_1, x_2, \dots, x_p, n_1$  en el subconjunto  $D_1$  marcada por  $\omega_1$  y  $n_2$  en el subconjunto  $D_2$  etiquetado como  $\omega_2$ . Si se forma una combinación lineal de las componentes de  $x$ , se obtiene el producto escalar mediante la ecuación (2.3).

$$y = \omega^t x \tag{2.1}$$

y un conjunto correspondiente de  $n$  muestras  $y_1, y_2, \dots, y_n$  dividido en los subconjuntos de  $y_1$  e  $y_2$ . Geométricamente, si  $||\omega|| = 1$ , cada  $y_i$  es la proyección de la  $x_i$  correspondiente en una línea en la dirección de  $\omega$ . En realidad, la magnitud de  $\omega$  no es de importancia real, ya que se limita a las escalas de  $y$ . Sólo la dirección de  $\omega$  es importante. En la Figura 2.2 se muestra una proyección de la recta  $\omega$  en dos diferentes direcciones, en la figura de la derecha se muestra una mayor separación entre los puntos proyectados de color rojo y negro.



**Figura 2.1:** *Proyección de las muestras en dos líneas diferentes. a) Muestra una menor separación entre los puntos negros y rojos. b) Muestra una mayor separación entre los puntos proyectados.*

Ahora bien, las funciones discriminantes lineales son relativamente fáciles de calcular y en la ausencia de información que sugiera lo contrario, los clasificadores lineales son una atractiva opción para clasificadores de prueba inicial.

### 2.2.2. Análisis de Componentes Principales

El método de componentes principales se remonta a Pearson (1901), aunque el procedimiento general tal como se conoce hoy tuvo que esperar a Harold Hotelling cuyo trabajo pionero apareció en 1933.

El campo del análisis multivariante se compone de técnicas estadísticas que tienen en cuenta dos o más variables aleatorias relacionadas como una sola entidad y los intentos de producir un resultado global tomando la relación entre las variables en cuenta.

El método o análisis de componentes principales es principalmente una técnica analítica de datos que obtiene transformaciones lineales de un grupo de variables correlacionadas de tal manera que se consiguen ciertas condiciones óptimas. La más importante de estas condiciones es que las variables transformadas no están correlacionadas. Su uso principal es como una técnica descriptiva, también puede ser utilizado en muchos procedimientos de inferencia.

El punto de partida para el PCA es la matriz de covarianza de la muestra  $S$  (o la matriz de correlación). Para un problema de  $p$ -variables, como se muestra en la ecuación (2.4)

$$S = \begin{bmatrix} s_1^2 & s_{12} & \dots & s_{1p} \\ s_{21} & s_2^2 & \dots & s_{2p} \\ \cdot & \cdot & \cdot & \cdot \\ s_{1p} & s_{2p} & \dots & s_p^2 \end{bmatrix} \quad (2.2)$$

Donde  $s_i^2$  es la  $i$ -ésima varianza de la variable  $x_i$  y  $s_{ij}$  es la covarianza

entre las variables  $i$ -ésima y  $j$ -ésima. Si las covarianzas no son iguales a cero, indica que existe una relación lineal entre estas dos variables, la fuerza de esa relación está representada por el coeficiente de correlación,  $r_{ij} = s_{ij}/(s_i s_j)$ .

El método de componentes principales se basa en un resultado clave de álgebra matricial:  $A$  simétrica de  $p \times p$ , matriz no singular, como matriz de covarianza  $s$ , se puede reducir a una matriz diagonal  $L$  premultiplicanda y postmultiplicada por una matriz ortonormal particular  $U$  tal como se muestra en la ecuación (2.5)

$$U' S U = L \quad (2.3)$$

Los elementos diagonales de  $L$ ,  $l_1, l_2, \dots, l_p$ , se llaman las raíces características, raíces latentes o eigenvalores de  $S$ . Las columnas de  $U$ ,  $u_1, u_2, \dots, u_p$  son llamados los vectores característicos o eigenvectores de  $S$ . Las raíces características se pueden obtener a partir de la solución de la siguiente ecuación, llamada la ecuación característica:

$$|S - U| = 0 \quad (2.4)$$

donde  $I$  es la matriz identidad. Esta ecuación produce un polinomio de grado  $p$  a partir del cual se obtienen los valores de  $l_1, l_2, \dots, l_p$ . Los vectores característicos pueden entonces ser obtenidos por la solución de la ecuación (2.7)

$$|S - lI|t_i = 0 \quad (2.5)$$

Y

$$u_i = \frac{t_i}{\sqrt{t_i' t_i}} \quad (2.6)$$

Estos vectores característicos conforman la matriz  $U$ , tal como se expresa en la ecuación (2.9)

$$u = |u_1 \quad u_2 \quad \dots \quad u_p| \quad (2.7)$$

Con esta transformación del eje principal, se transformará las  $p$  variables correlacionadas  $x_1, x_2, \dots, x_p$  en nuevas variables no correlacionadas  $z_1, z_2, \dots, z_p$ . Los ejes de coordenadas de estas nuevas variables se describen por los vectores característicos  $u_i$  que componen la matriz  $U$  de cosenos de dirección utilizados en la transformación de la ecuación (2.10):

$$z = U' |x - \bar{x}| \quad (2.8)$$

Las variables transformadas se llaman los componentes principales de  $x$ . El  $i$ -ésimo componente principal está descrito como en la ecuación (2.11)


$$z_i = u_i' |x - \bar{x}| \quad (2.9)$$

y tendrá media cero y varianza  $l_i$ , la  $i$ -ésima raíz característica.

### 2.2.3. Red Neuronal Artificial

Una red neuronal artificial o simplemente red neuronal (*Neural Network*, *NN*) es un método de procesamiento de información inspirada en sistemas biológicos, representa uno de los modelos matemáticos más usados en una amplia gama de campos de aplicación.

En términos del campo de la biología, las neuronas tienen una gran cantidad de ramas llamadas dendritas que actúa como un conducto para la estimulación eléctrica recibida desde otras células neuronales hacia el núcleo o núcleo celular. En este núcleo, el estímulo es tomado y la neurona genera una excitación eléctrica que es enviada a través del axón a la sinapsis, que son el enlace con otras neuronas y donde la intensidad de la excitación transmitida puede ser modificada. En base a este proceso, las redes neuronales artificiales fueron diseñadas para simular el comportamiento biológico.



**Figura 2.2:** Esquemas de neuronas. a) Neurona biológica, b) Neurona artificial

Una red neuronal artificial consiste de una capa de entrada de neuronas (o nodos), una o dos (incluso tres) capas ocultas de neuronas, y una capa final de neuronas de salida. En la Figura 2.2 se muestra una típica arquitectura de una red neuronal, donde se muestran las conexiones con las neuronas. Cada conexión está asociada con un número llamada peso o ponderación. La salida  $h_i$ , de la neurona  $i$  en la capa oculta es

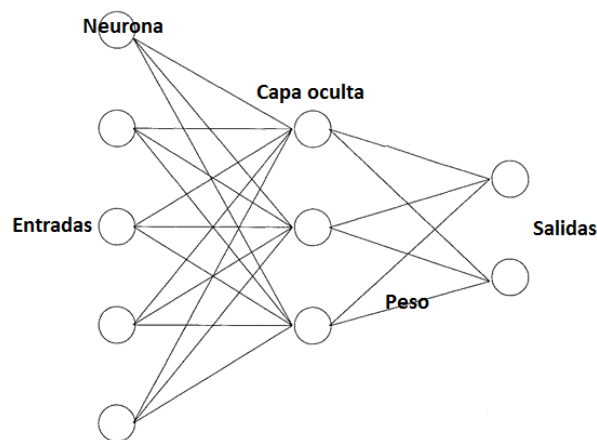
$$h_i = \sigma\left(\sum_{j=1}^N V_{ij}x_j + T_i^{hid}\right)$$



Donde  $\sigma$  es llamada función de activación (o transferencia),  $N$  el número de neuronas de entradas,  $V_{ij}$  los pesos,  $x_j$  la entrada hacia las neuronas de entrada y  $T_i^{hid}$  los términos de umbral de las neuronas ocultas. El propósito de la activación es además de introducir una red no lineal en la red neuronal, unir el valor de las neuronas de modo que la red neuronal no quede paralizada por neuronas divergentes. Un ejemplo común de la función de activación es la función sigmoidea (o logística) definida como

$$\sigma(u) = \frac{1}{1 + \exp(-u)}$$

Otras posibles funciones de activación son el arco tangente y la tangente hiperbólica. Estas tienen una respuesta similar a la función sigmoidea en la entrada, pero difiere en los rangos de salida.



**Figura 2.3:** *Arquitectura de una red neuronal artificial*

Se ha demostrado que una red neuronal construida de la manera anterior puede aproximar cualquier función computable a una precisión arbitraria. Los números dados a las neuronas de entrada son variables independientes y los devueltos por las neuronas de salida son variables dependientes de

la función que es aproximada por la red neuronal. Las entradas y salidas de una red neuronal pueden ser binarias (como sí o no) o incluso símbolos (verde, rojo, ...) cuando los datos están codificados adecuadamente. Esta característica confiere un amplio rango de aplicabilidad a redes neuronales, como el diagnóstico, a través de un proceso de aprendizaje. La NN representa un algoritmo no lineal, multivariable y no paramétrico (Theodoridis and Koutrombas, 2009).

Algunos de los aspectos a considerar a la hora de configurar una red neuronal son: el número de neuronas de cada capa, este está directamente relacionado con el número de variables de entrada o características. El número de neuronas en la capa de salida es directamente el número de elementos de salida o clases. Algo que no está dado directamente es la inicialización de valores. Si los valores de inicio de los pesos son cercanos a cero, la parte operativa de función de transferencia sigmoidea se comporta de manera lineal haciendo que la red neuronal tenga un modelo aproximadamente lineal. En general, los valores de inicio de los pesos son valores aleatorios cercanos a cero. Por lo tanto, el modelo comienza de forma casi lineal y se vuelve no lineal a medida de que los pesos van aumentando. Pesos inicializados con un valor exacto de cero provoca que haya derivadas cero y simetría perfecta por lo cual el algoritmo nunca cambia. Mientras que inicializar los valores muy grandes conduce a soluciones muy pobres.

Otra característica importante a considerar en la NN son la cantidad de unidades y capas ocultas. Por lo general tener demasiadas unidades ocultas es mejor que tener pocas. Con pocas unidades ocultas, el modelo podría no tener suficiente flexibilidad para capturar las no linealidades de los datos, mientras

que con demasiadas unidades ocultas, los pesos se reducen casi a cero usando la cantidad adecuada. Por lo general el número de unidades ocultas está en un rango de 2 a 100, la selección de este número depende de la práctica que se desea realizar y la experiencia del diseñador. Aunque por lo general una o dos capas son utilizadas para resolver la mayor parte de los problemas de clasificación.

## 2.3. Fallas en cadenas cinemáticas y condiciones de operación

### 2.3.1. Fallas por Barras Rotas

La falla más común en rotores son las barras rotas en los devanados del rotor. Estas fallas introducen anomalías en el campo magnético del entrehierro que produce una componente armónica de frecuencia  $f_{brb}$  en el espectro de corriente de línea cerca de la componente fundamental. Las componentes armónicas de la falla  $f_{brb}$  con relación a la frecuencia fundamental están dadas por (2.15), donde  $p$  es el número de polos,  $s$  unidades de deslizamiento del motor y  $k/p$  denota los valores característicos del motor.

$$f_{brb} = \left( \frac{(1-s)k}{p} \pm s \right) f_1 \quad \frac{k}{p} = 1, 3, 5, \dots \quad (2.10)$$

La componente armónica del lado izquierdo se obtiene sustituyendo  $k/p = 1$ . Esta componente produce oscilaciones en la velocidad del rotor, originando una nueva familia de fallas de componentes, con frecuencias dadas por.

$$f_{brb} = (1 \pm 2k_s) f_1 \quad k = 1, 3, 5, \dots \quad (2.11)$$

Las barras rotas no causan fallas inmediatas en el motor, sin embargo, estas pueden causar serios problemas debido a sus efectos secundarios como:

sobrecalentamiento, golpeo de barra, daños en el aislamiento del motor y consecuentemente falla en el devanado (Garcia-Ramirez *et al*, 2012).

### 2.3.2. Excentricidad de carga en el eje

Un sistema mecánico corresponde a uno que, durante una operación normal, todas las fuerzas y pares relacionados mantienen la magnitud, dirección y sentido. En los casos en que esto no se logra, el sistema relacionado se encuentra bajo algún tipo de desbalance.

Existen múltiples casos de desbalance en sistemas rotatorios, por ejemplo una excentricidad mecánica, esta puede presentarse dentro del motor de inducción y es la condición de desigualdad del entrehierro que existe entre el estator y el rotor. Otro caso de desbalance que afecta a la maquinaria industrial es la excentricidad en la carga en el eje del rotor. Este tipo de oscilaciones en la carga por lo regular se producen en sistemas que operan a baja frecuencia con una velocidad de carga lenta produciendo componentes en las cercanías de la frecuencia de rotación. Este efecto de excentricidad se produce por cargas dependientes de la posición del rotor, por ejemplo en compresores, así como variación de carga periódica o por condiciones de defecto mecánico en el acoplamiento o en la carga. Como bien se mencionó, este efecto de la carga se produce mayoritariamente en sistemas que operan a baja frecuencia por lo regular en aplicaciones donde los acoplamientos de reducción de velocidad como poleas o cajas de engranes se usan para producir una salida mecánica de baja velocidad y alta torsión, por ejemplo en agitadores, sopladores, pulverizadores, transportadores y otras aplicaciones industriales como se muestra en la Figura 2.4.



**Figura 2.4:** *Motor de inducción conduciendo un transportador operando a baja velocidad y alto torque.*

### **2.3.3. Detección de la frecuencia de oscilación de la carga a baja frecuencia**

Las oscilaciones en el torque inducidas por la baja frecuencia de rotación debida al desbalance o desalineamiento en la carga se transfieren a través de los acoplamientos e inducen componentes próximos a las bandas laterales de la frecuencia de rotación en la corriente del estator. Los acoplamientos para la reducción de la velocidad de rotación se usan generalmente en aplicaciones industriales donde se busca un alto torque a la salida de la cadena cinemática como en trituradoras, pulverizadoras o transportadoras. Cuando se realiza el movimiento de una carga con un motor de inducción a través de una caja de engranes se genera un desbalance o desequilibrio debido a la estructura asimétrica del dicho acoplamiento. Al tener un radio de reducción de velocidad  $r$ , la frecuencia de rotación de la carga se reduce igualmente en un radio de  $r$ . Las oscilaciones de salida de la carga se reflejan en una frecuencia  $f_r/r$  que se transmiten a través de la cadena cinemática hasta el

rotor y son percibidas por la corriente del estator. El efecto de esas oscilaciones de baja frecuencia dan como resultado componentes de frecuencia  $f_{carga}$  en la corriente del estator que están dadas por

$$f_{carga} = f_s \pm k f_r / r = f_s \pm k(1 - s) f_s / (pr) \quad (2.12)$$

Donde  $f_s$  es la frecuencia fundamental de suministro,  $s$  es el desplazamiento (*slip*) y  $k$  es un entero positivo.  $p$  es el número de pares de polos del rotor. La componente  $f_r$  se refiere a anomalías mecánicas en el motor, acoplamiento o carga que interrumpen la rotación equilibrada, alineada o concéntrica del rotor, éstas causan vibración, deterioro en el motor y en los componentes de carga (Nandi *et al*, 2005 - Culbert *et al* 2007).

---

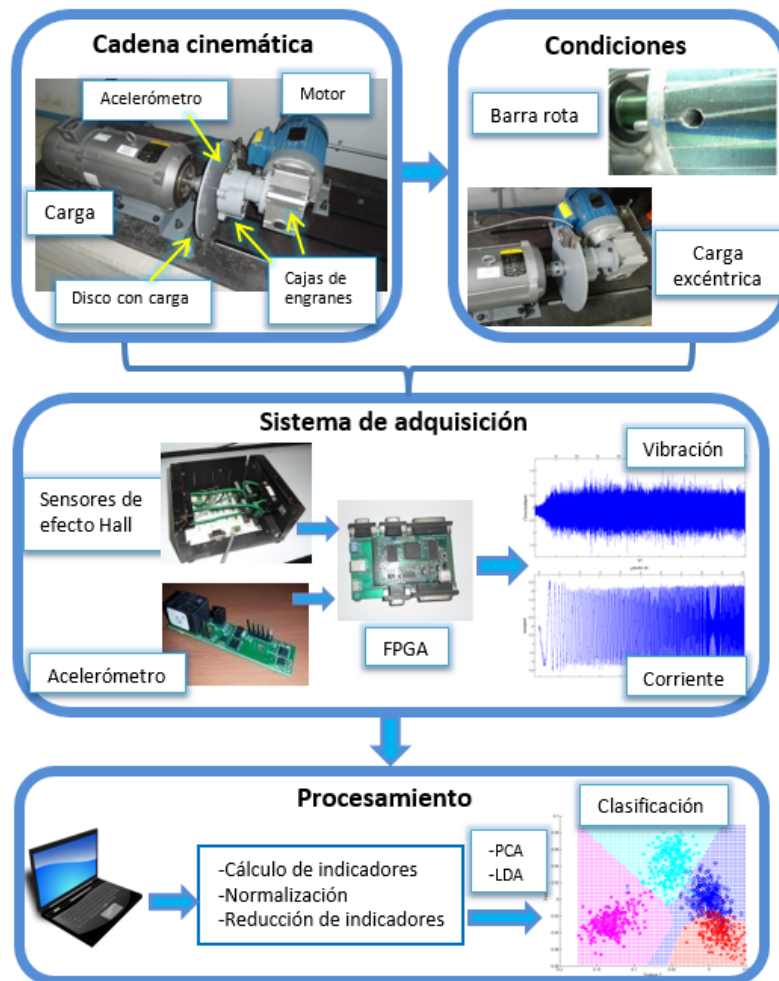
## Capítulo 3

### Metodología

---

### 3. Metodología

En este capítulo se presenta la metodología que se llevó a cabo para cumplir con los objetivos de este trabajo. En la Figura 3.1 se presenta un diagrama a bloques de las diferentes etapas que comprenden el desarrollo de este trabajo de investigación. Como ya se ha planteado, la finalidad este trabajo es proponer una metodología confiable basada en la extracción de indicadores estadísticos para realizar un análisis de fallas en una cadena cinemática, y para llevar a cabo dicha tarea se plantean los siguientes pasos a realizar: primero, hacer un acondicionamiento del banco de pruebas; con la finalidad de reproducir fallos inducidos controlados se armó una cadena cinemática que operara bajo las condiciones deseadas, esta cadena cinemática está compuesta de un motor de inducción, dos cajas de engranes, un disco para para montar cargas, un generador de corriente directa, un arrancador y un variador. Después obtener una base de datos de la cadena cinemática operada con los distintos casos a analizar, para ello se usaron sensores de vibración (acelerómetro) y corriente (sensor Hall) y una tarjeta FPGA para la adquisición. Luego se realizó un procesamiento a las señales obtenidas y finalmente se hizo un análisis de los indicadores de falla obtenidos.



**Figura 3.1:** Metodología propuesta.

En este trabajo se analizaron los datos con desbalance en la carga de 3, 5 y 10 % del par nominal, además con fallo de media y una barra rota. Se realizaron las pruebas en la cadena cinemática y posteriormente se hizo un estudio de indicadores estadísticos de las fallas.




### 3.1. Banco de Pruebas

Se construyó una bancada para poder realizar las pruebas experimentales. Dicho banco experimental consta de una cadena cinemática voluble de tal manera que se puedan hacer cambios con la finalidad de reproducir fallas inducidas. El banco experimental utilizado para las pruebas con diferentes índices de fallas se muestra en la Figura 3.2.

El banco de pruebas está compuesto de los siguientes elementos: un motor de inducción serie WEG-00236ET3E145T-W22 de dos polos que opera con una alimentación nominal de 220V y tiene una potencia de 2HP, la velocidad de rotación es controlada a partir de un variador de frecuencia modelo WEG-CFW08, el cual tiene un rango de operación desde 3Hz a 100Hz con una resolución de 0.1Hz. El motor de inducción se conecta a una etapa de reducción de velocidad a través de dos cajas de engranes, que a su vez aumentan el par de salida. La primera caja de engranes (NORD SK-1SI50-1) que sirve como reductora de velocidad está conectada del motor hacia otra caja reductora, tiene una relación de reducción de 10:1. La segunda caja reductora modelo BALDOR-GCF4X01AA cuenta con una reducción 4:1. Entre la caja de engranes y la carga mecánica se encuentra acoplada una flecha con un disco, dicho disco cuenta con perforaciones cerca de su periferia de tal manera que se pueden colocar masas para producir un desbalance en la carga. Finalmente la carga mecánica, que es un generador de DC (BALDOR-CDP3604), como ya se mencionó el generador se usó como carga mecánica no controlada y representa alrededor de 20% de carga nominal.

Todos los elementos de la cadena cinemática se encuentran montados sobre una base rígida de tal manera que se aminoran las vibraciones externas. El variador con el cual se opera el motor está colocado en un tablero en donde además se encuentra un arrancador (SIEMENS) y toda la instalación eléctrica para la puesta en marcha de la cadena cinemática.




**Figura 3.2:** *Banco experimental.*

### 3.2. Casos de estudio

En este trabajo se evaluarán dos casos de estudio de fallo en motores de inducción que adicionalmente serán estudiados bajo una condición de carga excéntrica. Se realizarán adquisiciones de vibración, corriente, voltaje y velocidad para ambas situaciones. Los casos que se analizarán son fallos por barra rota y fallos en rodamientos. La finalidad de estos dos casos de estudio se basa en poder hacer una buena clasificación entre fallo y la condición operativa de desbalance en la cadena cinemática.

### 3.2.1. Motor de Inducción con barras rotas y excentricidad


Para realizar el análisis de falla en barra rota se fabricó la avería de manera inducida haciendo una perforación de 7.9 mm de diámetro en una las barras del rotor, esta perforación se muestra en la Figura 3.3 a). Para producir el efecto de excentricidad se unió un disco delgado al eje entre la salida de la segunda caja de engranes y el generador que funciona como carga; para generar dicho efecto de desbalance se colocaron masas en una de las perforaciones que se encuentran casi en la periferia del disco, tal como se muestra en la Figura 3.3 b). La masa colocada se varió para tres casos, en donde la carga fuera aproximadamente 3 %, 5 % y 10 % del par nominal. Dichas oscilaciones de carga se generan a baja frecuencia debido a la doble reducción colocada en el eje del motor. Para una frecuencia de operación de 60 Hz, se tiene primero un reductor de 4:1 seguido de una reducción de 10:1, para lo cual la frecuencia de oscilación de la masa sería aproximadamente 1.5 Hz.



**Figura 3.3:** a) *Fallo en barra rota*, b) *Disco con desbalance*

### 3.3. Sistema de Adquisición


La cadena cinemática cuenta con diferentes sensores que permiten su monitoreo, dentro de los cuales se encuentran un sensor inercial montado sobre una de las cajas de engranes Figura 3.3 a), dicho sensor cuenta con un acelerómetro triaxial tipo MEMS (Microelectromechanical Systems) modelo LIS3L02AS4 capaz de medir aceleraciones en un rango de  $\pm 16$  g sobre un ancho de banda de hasta 1.5KHz para cada uno de los ejes. También cuenta con un encoder incremental de 5000 cuentas usado para medir la velocidad angular de salida del generador Figura 3.3 b).



**Figura 3.4:** a) *Acelerómetro*, b) *Encoder*

Otros componentes de monitoreo que se utilizaron fueron los sensores de efecto Hall (Tamura- L08P050D15) para medir la corriente de cada una de las tres líneas del estator en el motor de inducción, estos sensores tienen un ancho de banda de hasta 100kHz, un tiempo de respuesta de  $10\mu$  s y una linealidad a la salida de menor al  $\pm 1\%$ , los tres sensores están colocados en una tarjeta con un proceso de acondicionamiento, como se muestra en la Figura 3.4.


Las señales de corriente, velocidad y aceleración son adquiridas a través de una tarjeta de adquisición de datos (PLCUAQ8x16) diseñada por el grupo de investigación HSPDigital de la Universidad Autónoma de Querétaro, basada en una FPGA Spartan 3EXC3S1600 mostrada en la Figura 3.5. La tarjeta cuenta con 8 entradas -salidas analógicas, 16 entradas-salidas digitales, opera con un reloj de 48MHz, además de un convertidor analógico-digital (ADS7841) de 12 bits y cuatro canales seriales y un convertidor digital-analógico (DAC7565) de 12 bits. Tiene una memoria SRAM estática (ISSI-IS61LV5128AL).



**Figura 3.5:** *Tarjeta de acondicionamiento con sensores de corriente.*

Para la transmisión de datos la tarjeta cuenta con un conector RS-232 y USB. Los datos se enviaron hacia la PC por medio del protocolo USB. La frecuencia de muestreo y el tiempo de adquisición son establecidos desde la PC. Se establecen dos frecuencias de muestreo, una para las señales de vibración y otra para las señales de corriente, voltaje y velocidad. Para este trabajo la adquisición de señales de vibración se hizo a una frecuencia de 4

kHz y para la adquisición de las señales de corriente se estableció en 3 kHz. El tiempo de adquisición fue de 240 segundos.



**Figura 3.6:** Tarjeta de adquisición FPGA.

### 3.4. Procesamiento de Señales

Como se mencionó anteriormente, se realizó la adquisición de varias señales en tiempo (vibración, corriente, voltaje, velocidad). Para el estudio de la cadena cinemática, como ya se revisó en los antecedentes, es suficiente que el análisis se centre únicamente en las señales de vibración y las señales de corriente. Las mediciones se hicieron para cada uno de los casos de estudio, la primera de las adquisiciones se realizó teniendo una cadena cinemática con todos los elementos saludables, posteriormente se realizaron adquisiciones introduciendo las fallas y la carga con desbalance. En la Tabla 1 se muestran las condiciones de prueba para las cuales se realizaron adquisiciones.

Una vez teniendo las mediciones en tiempo de vibración y corriente para cada caso de estudio se prosigue a realizar un procesamiento que se describe a continuación.

**Tabla 3.1:** *Matriz de pruebas.*

		Nivel de carga operado a 30 Hz				Nivel de carga operado a 60 Hz			
		0%	3%	5%	10%	0%	3%	5%	10%
Estado de operación del motor	Sano	1	2	3	4	5	6	7	8
	½ Barra rota	9	10	11	12	13	14	15	16
	1 Barra rota	17	18	19	20	21	22	23	24
	Fallo en rodamiento	25	26	27	28	29	30	31	32

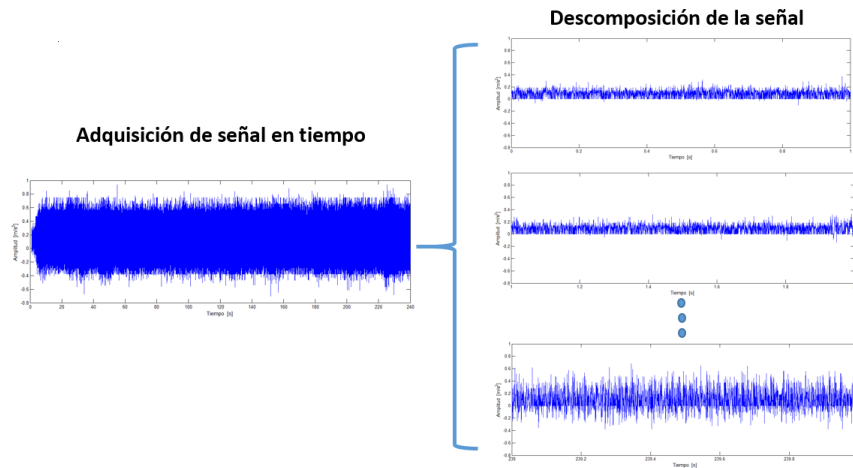
### 3.4.1. Segmentación de las Señales en Tiempo

El diagnóstico de fallas en cadenas cinemáticas y maquinaria rotativa en general está recibiendo cada vez más atención. Señales de corriente, vibración, velocidad y voltaje son analizadas para extraer información que permita caracterizar y clasificar averías en los elementos rotativos. Sin embargo, debido al comportamiento no lineal, a condiciones de operación y/o ruidos en la maquinaria, la información extraída de las señales varía para cada muestra dificultando el análisis que permita una correcta detección y clasificación de fallos. Para dar solución a la clasificación de fallos, recientemente se han empleado varias metodologías basadas en el cálculo de características estadístico-temporales las cuales han sido aplicadas con éxito Meng G. *etal* (2015) y Wei L. *et al* (2014).

Las metodologías de extracción y evaluación de características estadístico-temporal se basan en la segmentación de señales de vibración o corriente. Esta segmentación o seccionamiento se hace para tramos que sean lo suficientemente representativos de la señal. Como se dijo anteriormente, el tiempo de adquisición para las señales fue de 240 segundos, por lo que se propone realizar un seccionamiento de 1 segundo para las señales, teniendo entonces 240



tramos para la segmentación de la señal, como se muestra en la Figura 3.8.



**Figura 3.7:** Segmentación en tramos de las señales

### 3.4.2. Cálculo de Indicadores Estadístico-Temporal

Una vez realizada la segmentación de la señal se busca resaltar información relevante de cada uno de los tramos. Una de las formas en que se obtiene información significativa de las señales adquiridas es a través del cálculo de características estadístico-temporal. Con la segmentación y cálculo de características es posible realizar una buena descripción de la condición del sistema, permite la identificación de fallos y averías, así como condiciones de operación que puedan ocasionar disturbios. Algunas metodologías de estudio en sistemas rotativos realizan un procesamiento previo al cálculo de características estadístico-temporal, como puede ser técnicas basadas en el dominio del tiempo, dominio de la frecuencia o una combinación de dominio tiempo-frecuencia. Aunque la aplicación de dichas técnicas en ocasiones mejora la caracterización de las señales, también incrementa el costo computacional, por lo cual solo es conveniente aplicar en sistemas donde es difícil realizar



una correcta identificación y/o clasificación de fallos. Los parámetros o características estadístico-temporales que se calcularan para obtener información significativa de las señales son: la media, el valor máximo, RMS (*root mean square*), SRM (*square root mean*), derivación estándar, varianza, RMS shape factor, SRM shape factor, factor cresta, *latitude factor*, *impulse factor*, skewness, kurtosis, quinto momento normalizado y sexto momento normalizado. Este conjunto propuesto de quince características se muestra en la Tabla 3.2.

**Tabla 3.2:** *Indicadores Estadísticos Basados en el Tiempo*

Media	$\bar{x} = \frac{1}{n} \cdot \sum_{k=1}^n  x_k $	(1)
Valor Máximo	$\hat{x} = \max(x)$	(2)
Root mean square	$RMS = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k)^2}$	(3)
Square root mean	$SRM = \left( \frac{1}{n} \cdot \sum_{k=1}^n \sqrt{ x_k } \right)^2$	(4)
Derivación Estándar	$\sigma = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2}$	(5)
Varianza	$\sigma^2 = \frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2$	(6)
RMS Shape factor	$SF_{RMS} = \frac{RMS}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$	(7)
SRM Shape factor	$SF_{SRM} = \frac{SRM}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$	(8)
Factor Cresta	$CF = \frac{\hat{x}}{RMS}$	(9)
Latitude factor	$LF = \frac{\hat{x}}{SRM}$	(10)
Impulse factor	$IF = \frac{\hat{x}}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$	(11)
Skewness	$S_k = \frac{E[(x_k - \bar{x})^3]}{\sigma^3}$	(12)
Kurtosis	$k = \frac{E[(x_k - \bar{x})^4]}{\sigma^4}$	(13)
Quinto Momento	$5thM = \frac{E[(x_k - \bar{x})^5]}{\sigma^5}$	(14)
Sexto Momento	$6thM = \frac{E[(x_k - \bar{x})^6]}{\sigma^6}$	(15)

El cálculo de estos 15 datos estadístico-temporal se realiza para cada una de las 240 secciones de la señal, con ello se obtiene una representación relevante de características estadístico-temporal de las magnitudes físicas adquiridas. A continuación se describe cada uno de ellos.

### Media

Es el promedio matemático de todos los términos incluidos en una distribución de valores  $x_k$  con  $k = 1, 2, 3, \dots, m$

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n |x_k| \quad (3.1)$$

### Valor máximo

Es el valor más grande de toda la distribución de valores  $x_k$  con  $k = 1, 2, 3, \dots, m$

$$\hat{x} = \max(x_k) \quad (3.2)$$

### 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

$$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k)^2} \quad (3.3)$$

### Square root mean (SRM)

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

$$SRM = \left( \frac{1}{n} \sum_{k=1}^n \sqrt{|x_k|} \right)^2 \quad (3.4)$$

### Derivación estándar

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

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2} \quad (3.5)$$

### Varianza

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 medida de qué tan dispersa es una distribución. Se define como:

$$\sigma^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \quad (3.6)$$

### RMS shape factor

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*. Se define como:

$$SF_{RMS} = \frac{RMS}{\frac{1}{n} \sum_{k=1}^n |x_k|} \quad (3.7)$$

### SRM shape factor

Es la combinación estadística del SRM y el *shape factor*. Se define como:

$$SF_{RMS} = \frac{SRM}{\frac{1}{n} \sum_{k=1}^n |x_k|} \quad (3.8)$$

### Factor cresta

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

$$CF = \frac{\hat{x}}{RMS} \quad (3.9)$$

### Latitud factor

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

$$CF = \frac{\hat{x}}{SRM} \quad (3.10)$$

### Impulse factor

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

$$IF = \frac{\hat{x}}{\frac{1}{n} \sum_{k=1}^n |x_k|} \quad (3.11)$$

### Skewness

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 skewness 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

$$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^3}{\sigma^3} \quad (3.12)$$

### **Kurtosis**

Es el cuarto momento central normalizado. Describe cómo 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

$$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^4}{\sigma^4} \quad (3.13)$$

### **Quinto momento**

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

$$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^5}{\sigma^5} \quad (3.14)$$

### **Sexto momento**

$$S_k = \frac{\sum_{k=1}^n (x_k - \bar{x})^6}{\sigma^6} \quad (3.15)$$

### 3.4.3. Normalización de los Indicadores Basados en el Tiempo

Las características estadístico-temporales obtenidas obedecen aproximadamente a distribuciones normales. Por ello se aplica un proceso de normalización de datos, el cual tiene como objetivo ajustar los valores de los datos estadístico-temporales en base a una medición primordialmente característica. Para el análisis de sistemas rotativos dicha medición característica se refiere a las mediciones adquiridas sin disturbios o comúnmente llamadas señales saludables. Así con la normalización se logra parametrizar condiciones defectuosas a partir de valores numéricos que permiten diferir entre señales extraídas con algún fallo y señales sin fallo alguno, o simplemente condiciones de operación diferentes a las condiciones normales.

La normalización de un conjunto de datos se obtiene a través de la ecuación

$$X_n = \frac{x_i - \bar{x}_i}{\sigma_i} \quad (3.16)$$

### 3.4.4. Selección de Indicadores Significativos

Con las 15 características estadístico-temporales propuestas, aplicadas a cada uno de los segmentos de las señales adquiridas de corriente y voltaje es posible obtener información que permite caracterizar la condición de la maquinaria. Sin embargo, usar un conjunto de alta dimensionalidad como el propuesto implica un alto costo computacional, además que irremediablemente puede contener información redundante y no significativa. Para hacer un proceso más eficiente y que además facilite una correcta clasificación de las condiciones consideradas se realiza un proceso de optimización basado en la selección de características estadístico-temporales (CET) que aporten

la información más significativa del sistema. Para esta optimización se hace uso de la técnica de Análisis por Componentes Principales (*Principal Component Analysis*) PCA. Con la técnica de PCA se busca encontrar un subconjunto de indicadores estadístico-temporales que proporcione una mejor representación y descartar aquellos que generan redundancia en el análisis. El análisis mediante PCA se basa en la acumulación de la varianza de los datos. Para realizar la optimización se hace el cálculo de los 15 indicadores estadístico-temporales a cada una de las señales de las condiciones consideradas, por ejemplo, si se desea hacer un análisis de clasificación de los fallos de media barra y una barra rota, se realiza la segmentación y cálculo de indicadores de tres condiciones, los dos fallos mencionado además de la condición sana de la cadena cinemática. Se normalizan cada uno de los indicadores con respecto a los indicadores sanos.

Ahora, para la aplicación de PCA se genera una matriz de representación (MR) de indicadores normalizados, colocando primero las correspondientes a los datos sanos normalizados, en donde cada renglón esta una sección de la segmentación de la señal y cada columna una característica estadístico-temporal, entonces la representación de la condición sana está dada por 240 renglones y 15 columnas. De igual manera se representan las otras dos condiciones, de media barra rota y una barra rota, que en total generan una matriz representativa de 720 renglones por 15 columnas. Se prosigue realizando el algoritmo de PCA calculando la desviación estándar de MR para obtener después una matriz de covarianza la cual nos permite realizar en conjunto con MR una representación de los datos en un espacio bidimensional. Ahora bien, al visualizar la proyección de los datos representativos para las tres condiciones se notará que hay un traslape o amontonamiento

de los datos de las condiciones, esto debido a la información redundante o de aportación poco significativa. Si bien, es posible que no haya un traslape entre clases aún se sugiere realizar la reducción de características para facilitar el cómputo y optimizar el proceso de clasificación. La optimización es un proceso manual el cual se realiza al computarizar la matriz de covarianza, la cual resulta ser una matriz cuadrada del número total de características utilizadas para la proyección, que en este caso sería de 15x15. La supervisión se hace analizando los datos de la proyección que corresponde a las dos primeras columnas, cada valor representa un dato Fisher, un valor de Fisher grande representa una distancia de separabilidad grande, mientras que un valor Fisher pequeño equivale a una distancia pequeña. Se busca que la separación sea lo más grande posible por lo cual se eliminan los indicadores que tienen un valor absoluto de Fisher pequeño y se realiza nuevamente el proceso de análisis de PCA con el nuevo subconjunto de indicadores estadístico-temporal.

Una vez realizado el proceso de optimización en el que se hizo una selección de los indicadores más significativos, sigue una etapa de extracción de características, en donde el subconjunto de características estadístico-temporales se somete a un proceso de compresión y transformación de base, esto se realiza mediante el Análisis Discriminante Lineal (*Linear Discriminant Analysis*) LDA. En esta nueva etapa se extrae un nuevo conjunto de características, las cuales son proyectadas en un espacio bidimensional que permite una interpretación visual de cada una de las condiciones analizadas. Adicionalmente esta representación bidimensional facilita la tarea de clasificación ya que se aumenta la capacidad discriminativa de cada una de las condiciones consideradas.



### 3.4.5. Clasificación de las Condiciones

La metodología propuesta para el diagnóstico de deficiencias en cadenas cinemáticas está basada en un procedimiento de análisis a partir de mediciones físicas realizadas en un banco experimental a las cuales se les realiza un proceso de segmentación por tramos para después hacer un cálculo de indicadores estadístico-temporal y posteriormente una selección de indicadores, extrayendo aquellos con información más significativa. La extracción de características permite una configuración simple para el último proceso de análisis de fallos y condiciones que es la clasificación de clases o condiciones. Este último paso de clasificación se realiza bajo una estructura de clasificación basada en Redes Neuronales Artificiales (*NeuralNetwork*, *NN*). La red neuronal artificial usa como entrada los coeficientes del subconjunto de características estadístico-temporales extraídas, que son empleadas para realizar la proyección bidimensional de las clases. La NN es un proceso matemático en cual se busca simular el comportamiento biológico de las neuronas, teniendo una etapa de aprendizaje que a través de una función defina un valor por el cual se le asigne a un conjunto de características o clases determinadas.

Como en las neuronas biológicas, en la red neuronal la unidad de procesamiento básica es una neurona. Esta produce una salida a partir de la suma de los pesos de cada una de las variables de entrada. Para llevar a cabo este procesamiento, la neurona básica llamada perceptrón, desarrolla un algoritmo capaz de generar un criterio para seleccionar un sub-conjunto a partir de un conjunto de componentes más grande. El algoritmo consiste que si las señales entrantes sumadas a través de pesos positivos o negativos tienen un valor mayor que un umbral  $U$ , la salida de la neurona es 1, en otro


caso es 0. Diferentes funciones de transferencia son usadas en el desarrollo de modelos para las neuronas. De manera general, es una función  $f(S_{ne-j})$  que normalmente es no lineal y la salida  $y$  de la neurona  $j$  está dada por la suma de las entradas  $x_{sum} = \{f_{e1}, f_{e2}, \dots, f_{eD}\}$ . El comportamiento característico de la neurona puede estar dado por:

$$y_j = f(S_{ne-j}) \tag{3.17}$$

donde:

$$S_{ne-j} = \sum_i = 1^D w_{ji} * f_{e-i} \tag{3.18}$$


En el cual  $w_{ij}$  es el  $i$ -ésimo peso de la  $j$ -ésima neurona. En la Figura 3.8 se muestra una representación de las operaciones en una neurona.



**Figura 3.8:** Representación del operador de una neurona

La función mayormente empleada dentro de las redes neuronales es la función sigmoide. Esta tiene una representación típica de S como se muestra en la Figura 3.9. Tiene altas capacidades de ajuste, dicha función está expresada como:

$$y_j = f(S_{ne-j}) = \frac{1}{1 + e^{-\alpha S_{ne-j}}} \quad (3.19)$$



**Figura 3.9:** *Función de transferencia sigmoidea*

Se desarrollara e implementará entonces una red neuronal artificial para cuantificar cada una de las clases consideradas en este análisis.

---

## Capítulo 4

### Experimentación y Resultados

---


## 4. Experimentación y Resultados

En este capítulo se presentan los resultados obtenidos tomando en cuenta las señales adquiridas para cada una de las condiciones consideradas, se hace el análisis aplicando cada uno de los pasos de la metodología propuesta. Se comienza realizando la segmentación de las señales a analizar, luego se calculan las características estadístico-temporales propuestas para en seguida hacer una extracción con las más significativas, posteriormente se hace un cambio de base y se genera una proyección bidimensional para finalmente realizar la validación de las condiciones por medio de un clasificador.

### 4.1. Validación del Análisis de Extracción de Indicadores Estadísticos Basados en Tiempo

Una vez hecha la implementados de los algoritmos de estudio en software para el análisis estadístico se hace uso de señales de una base de datos extraídas desde Case Western Reserve University (CWRU) para realizar la validación del método. La base de datos de CWRU cuenta con señales de vibración, como la que se muestra en la Figura, adquiridas en una cadena cinemática con diferentes condiciones para el estudio de fallos en rodamientos en motores de inducción. Las condiciones que se usan para la

validación son: señales con rodamientos en estado sano, señales con fallo en la pista interna, señales con fallo en la pista externa y señales con fallo en las bolas de rodamientos.



**Figura 4.1:** Señal de vibración de CWRU.

Las señales fueron adquiridas a una frecuencia de muestreo de 12 kHz, cada señal consiste en 10 segundos de adquisición. Primero se realiza la segmentación de cada una de las señales consideradas. La segmentación propuesta consiste en dividir la señal en tiempo en sub muestras, para lo cual a cada sub muestra se le calculan los 15 indicadores estadístico-temporales propuestos en la metodología (Tabla 3.2).

Se tiene entonces cuatro condiciones, las cuales se seccionaron en 100 muestras cada una y a cada una de las 100 muestras se calcula 15 características estadísticas. Prosiguiendo con la aplicación de la metodología se hace el análisis mediante PCA para realizar la discriminación de las características que no aportan información relevante. Se hace la supervisión en la matriz de covarianza obtenida a través de PCA de cada uno de los 15 indicadores calculados y se extrae un nuevo subconjunto que se muestra en la Tabla 4.1. Este nuevo subconjunto está formado por los siguientes indi-

cadadores: Valor Máximo, RMS, Skewness, *Latitude Factor*, *Crest Factor*, Kurtosis y Sexto Momento.


**Tabla 4.1:** *Subconjunto de Indicadores Estadísticos Basados en el Tiempo*

Valor Máximo	$\hat{x} = \max(x)$	(1)
Root mean square	$RMS = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k)^2}$	(2)
Skewness	$S_k = \frac{E[(x_k - \bar{x})^3]}{\sigma^3}$	(3)
Latitude factor	$LF = \frac{\hat{x}}{SRM}$	(4)
Crest factor	$CF = \frac{\hat{x}}{RMS}$	(5)
Kurtosis	$k = \frac{E[(x_k - \bar{x})^4]}{\sigma^4}$	(6)
Sixth moment	$6thM = \frac{E[(x_k - \bar{x})^6]}{\sigma^6}$	(7)

Con este subconjunto de características extraídas con PCA que maximizan la información representativa se procede a realizar una proyección bidimensional de las clases o condiciones consideradas. Esta proyección del subconjunto de características se muestra en la Figura 4.2.

Como se observa en la representación de datos, existen componentes con una agrupación buena. Sin embargo también se puede constatar que para algunas clases existe un traslape de puntos lo cual a la hora de realizar una clasificación generaría bastante confusión entre las condiciones por clasificar.


Una alternativa para solucionar esta problemática es aumentando la información con la que se pretende caracterizar el sistema. El primer análisis se realizó tomando en cuenta una señal de vibración cercana al motor de inducción, no obstante se tiene que el banco experimental de CWRU se realizaron mediciones de vibración en múltiples puntos, uno de ellos es en la base donde está colocada la bancada.



**Figura 4.2:** *Proyección de características extraídas mediante PCA con una señal de vibración.*

Se puede adicionalmente tomar otra señal y adicionarla al estudio hecho con la finalidad de aumentar la dispersión de cada caso. La manera de agregar dicha señal es realizando el mismo análisis de segmentación y de cálculo de características, aunque para esta parte solo se consideran las características del subconjunto ya extraído, se adicional dichas señales a la matriz de representación de PCA y se procede con la proyección de las clases. La proyección de las clases usando dos señales de vibración se muestra en la Figura 4.3.

Con el uso de dos señales de vibración se logra hacer que la separabilidad entre los casos de fallo en pista interna y el fallo de bolas sea más grande y permite separa ambos casos. Con la aplicación del Clasificador Difuso para uno de los caso se logra comprobar que existe una mejora entre el caso se estudió de una señal y el caso de estudio donde se usan dos señales. Los radios de clasificación para cada caso se muestran en la Tabla 4.2.



**Figura 4.3:** *Proyección de características extraídas mediante PCA con dos señales de vibración.*

Como se observa los radios de clasificación al hacer un análisis con dos señales en lugar del análisis con solo una señal de vibración aumentan en aproximadamente 20%. De acuerdo a esto, se constata que con un análisis con dos señales de vibración se obtienen buenos resultados realizar para la clasificación de fallos de rodamientos.

**Tabla 4.2:** *Radio de clasificación obtenidos con el Clasificador Difuso*

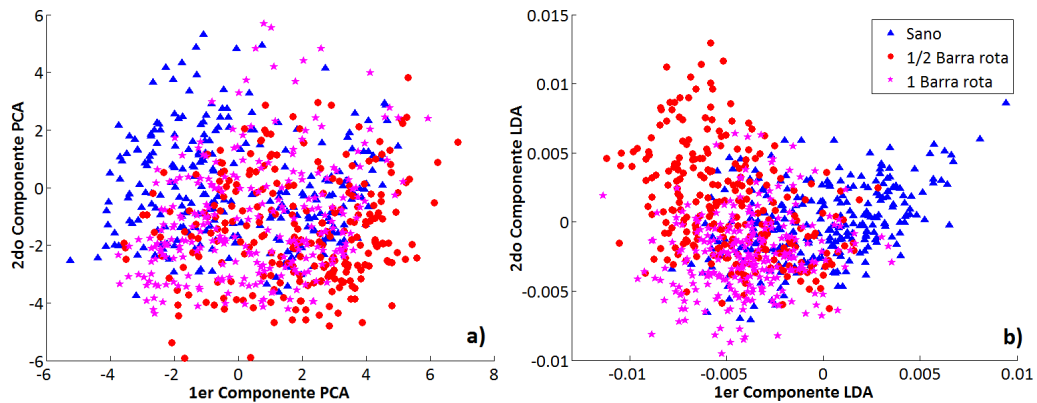
<i>Numero de señales de vibración</i>	<i>1 Señal de vibración</i>	<i>2 Señales de vibración</i>
Radios de clasificación obtenidos	73.5%	93.6%



## 4.2. Análisis Estadístico para Clasificación de Fallos en Barras de Rotor

Una vez validada la implementación en software de PCA con los casos de estudio se prosigue a realizar el análisis con los datos extraídos desde la bancada construida. El primer análisis que se realizó fue la clasificación de fallos en barras del rotor, se consideró tres casos de estudio, el sistema operando sin fallos, es decir saludable junto a dos condiciones de fallo, uno de media barra rota y otro de una barra rota. Estos casos de estudio se describieron ya en la metodología.

Realizando el análisis del cálculo de las 15 características estadístico-temporales para las tres condiciones y haciendo un análisis mediante PCA para señales de corriente se obtiene una proyección bidimensional como la que se muestra en la Figura 4.4 a). Esta representación indica que se tiene una dispersión muy mala entre clases y que resultaría casi imposible realizar una correcta clasificación. Poniendo a prueba el estudio de características mediante el Análisis Discriminante Lineal (LDA) para las mismas condiciones y las mismas señales de vibración se obtiene una proyección bidimensional como la mostrada en la Figura 4.4 b). De igual manera, se puede ver que existe un empalme o sobreposición entre las clases que representan las condiciones de operación de la cadena cinemática.

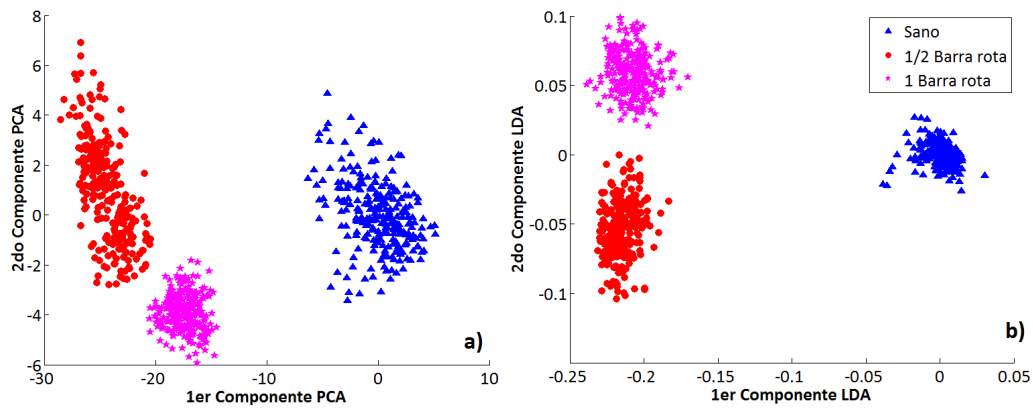


**Figura 4.4:** Análisis en señales de corriente para fallos en barras del rotor.

a) Proyección con PCA, b) Proyección con LDA

No obstante, al realizar un estudio a las señales de vibración se puede notar que se obtienen mejores resultados que usando señales de corriente. En la Figura 4.5 a), se muestra la proyección bidimensional de los 15 indicadores estadístico-temporales usando señales de vibración y haciendo un análisis mediante PCA.

En la Figura 4.5 b), de igual manera se hace el cálculo de los 15 indicadores estadístico-temporales, pero esta proyección corresponde al análisis de LDA, en donde también se tiene una buena dispersión entre las condiciones representadas.



**Figura 4.5:** *Análisis en señales de vibración para fallos en barras del rotor.*

*a) Proyección con PCA, b) Proyección con LDA*

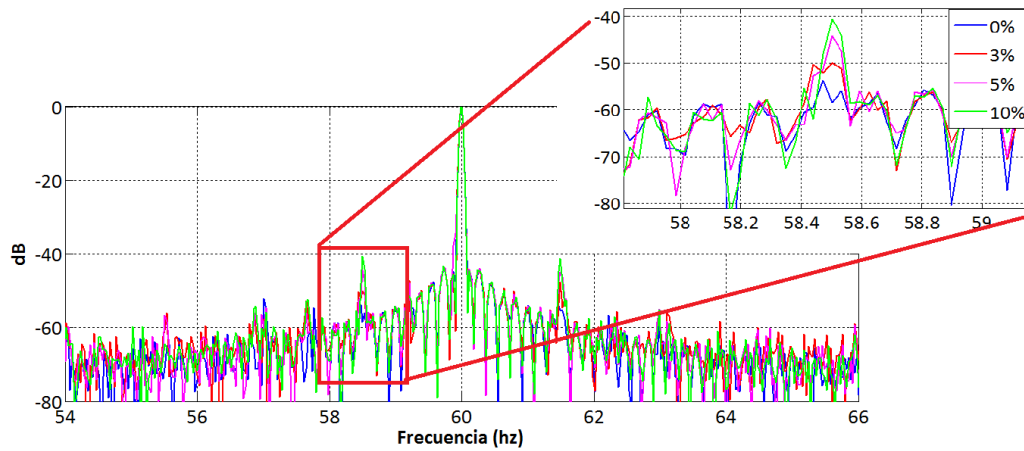
Para el caso de estudio de barras rotas mediante el cálculo de indicadores estadísticos se muestra que al emplear señales de vibración se obtienen buenos resultados a diferencia de usar señales de corriente en donde la proyección de datos es mala.

### 4.3. Identificación de Excentricidad de Masa

A continuación se presenta el análisis considerando además de fallos condiciones de operación con excentricidad de masa en el eje rotatorio. Antes de hacer un análisis con el cálculo y extracción de características estadístico-temporales es necesario aclarar el problema que puede presentar tener una condición de operación como es la excentricidad de masa. Una excentricidad de masa operando en un eje rotatorio, especialmente si se trata de un sistema operando a baja frecuencia, puede implicar frecuencias características similares a las frecuencias características de algunos fallos. Esto tiene una gran repercusión si se considera que muchos estudios para la detección de fallos consideran únicamente condiciones de operación con carga balanceada, sin embargo la presencia de un desbalance puede generar falsas alarmas de fallo en técnicas de estudio que no hacen consideración de esta condición de operación, y que al no tratarse de un fallo estrictamente genera errores en el diagnóstico de fallas.

Para el análisis de esta condición de desbalance se construyó el banco de pruebas que se mostró en la metodología. Realizando adquisiciones y un análisis de espectro se pudo identificar las señales características de la excentricidad cercanas a la frecuencia fundamental. En la Figura 4.6 se muestra el espectro en frecuencia y la identificación de esas frecuencias características para un desbalance de tres casos: 3 %, 5 % y 10 % de carga nominal.

En este estudio en frecuencia se puede constatar que la frecuencia generada por el desbalance de masa está bastante cerca a la frecuencia fundamental, algo muy similar ocurre cuando se analiza un espectro de frecuencia con fallo en barra rotas. El slip que se produce por efecto de la barra




**Figura 4.6:** Localización de carga excéntrica con FFT.

rota es muy cercano a la fundamental. En este sentido se podría tener el caso en que pudiera generar confusión a la hora de interpretar un espectro de frecuencia, en tanto no saber si se trata de un fallo o una condición de operación.

Basándose en las pruebas realizadas, se pudo constatar que la frecuencia producida por el fallo de barra rota es susceptible a ligeros modificaciones cuando ocurren cambios en la carga mecánica dentro de la cadena cinemática. Un cambio de carga mecánica hace que la frecuencia característica producida por un fallo en barra rota sea desplazada hacia la derecha o la izquierda según sea el caso correspondiente de la locación de la frecuencia de fallo, tal como se muestra de la Figura 4.7.

En esta figura se puede notar que las tres primeras singularidades más cercanas a la frecuencia fundamental, corresponden a frecuencias indicadoras de fallos para barra rota y que incrementan su cercanía hacia la frecuencia característica ocasionada por el desbalance de la carga excéntrica a medida que aumenta la carga en el generador eléctrico. Dicha cercanía podría generar confusión y error a la hora de intentar hacer un análisis para la detección o

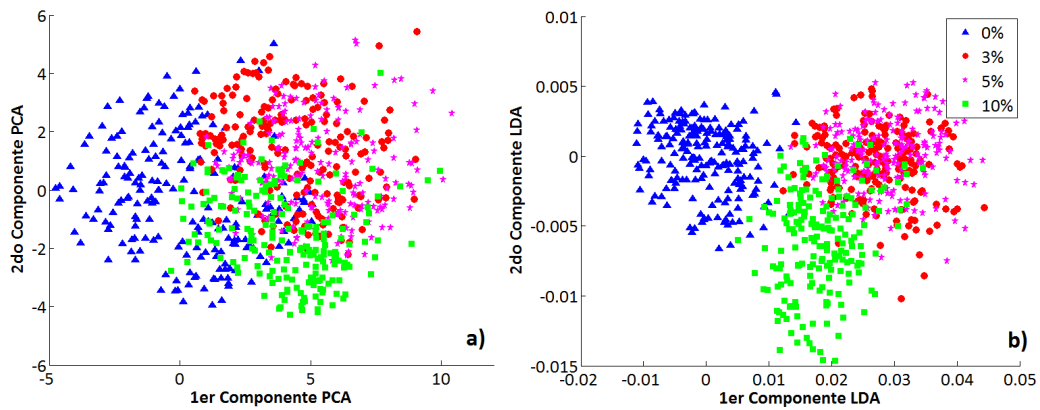


**Figura 4.7:** Barrido de la frecuencia de fallo ocasionado por el cambio de carga mecánica.

clasificación de fallos en barra rota. Si la frecuencia de fallo de barra rota y la frecuencia característica de la condición de operación son muy similares, es necesario realizar un proceso detallado de estudio para poder clasificar cada una de las consideraciones y tratar de evitar posibles errores de clasificación entre uno y otro.

#### 4.4. Análisis Estadístico para Condiciones de Operación con Excentricidad de Masa

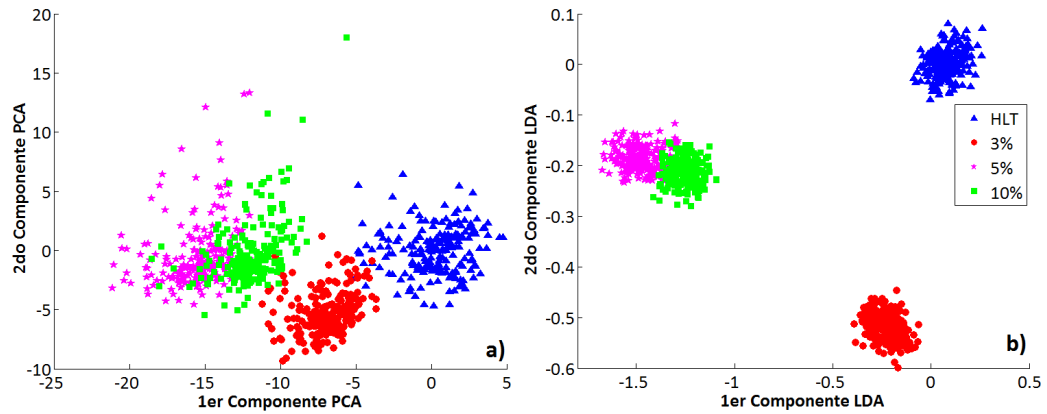
A continuación se muestran los resultados obtenidos para la identificación de carga excéntrica de masa, realizando un proceso de análisis estadístico. En las Figuras 4.8 a) y b) se muestran las proyecciones para un estudio bajo PCA y LDA correspondientemente realizado en señales de corriente.



**Figura 4.8:** Análisis en señales de corriente para identificación de excentricidad de masa. a) Proyección con PCA, b) Proyección con LDA

Los resultados mostrados indican que un análisis de PCA no sería capaz de hacer una buena separación entre clases, mientras que para un análisis bajo LDA sería capaz de diferenciar la condición de operación sometida a carga de la condición sana.

Ahora en las Figuras 4.9 a) y b) se muestran las proyecciones obtenidas, al igual que las proyecciones anteriores un análisis de PCA y LDA, solo que ahora se presenta el estudio para señales de vibración.



**Figura 4.9:** *Análisis en señales de vibración para identificación de excéntrica de masa. a) Proyección con PCA, b) Proyección con LDA*

Aquí se puede constatar que en el caso de LDA es posible obtener una mayor dispersión ya que incluso se logra separar el estado sano y uno de los niveles de carga considerados.

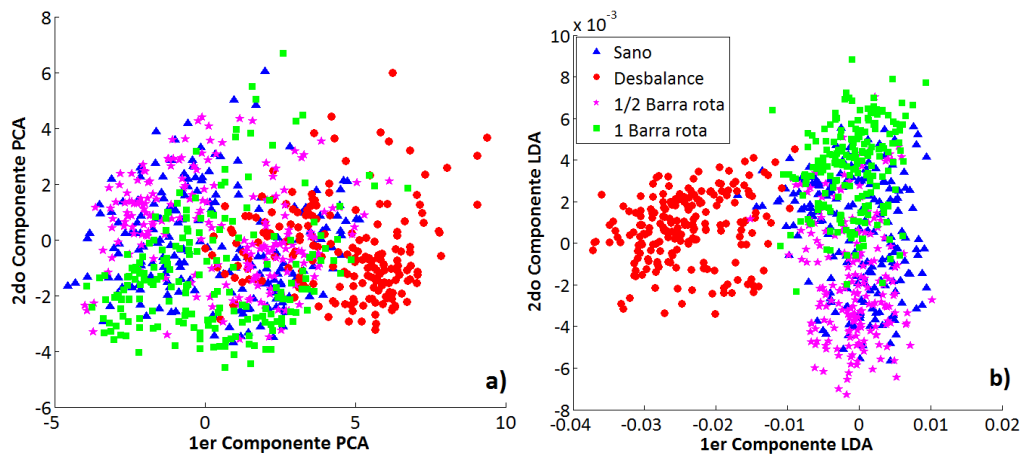


## 4.5. Análisis Estadístico de Fallo en Barra Rota y Condiciones de Operación con Excentricidad

Ahora se presenta el estudio en señales de corriente y vibración analizando las siguientes condiciones: sano, excentricidad para los tres niveles de carga 3 %, 5 % y 10 %, fallo de media barra rota en cuatro estados sin carga 0 % y carga de 3 %, 5 % y 10 % y finalmente fallo de una barra rota con 0 %, 3 %, 5 % y 10 % de carga excentrica. La finalidad de este análisis es poder realizar una buena clasificación y poder diferenciar entre cada uno de los casos a considerar. Así, por medio de un análisis de extracción de indicadores lograr diferenciar entre los fallos de barra rota y una condición de operación sometida a una carga excéntrica.

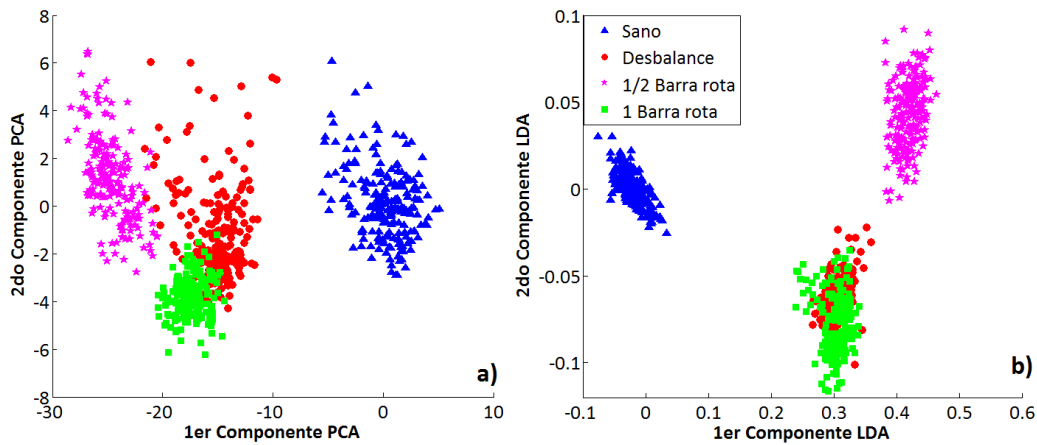
Los resultados de las proyecciones para cada análisis se muestran a continuación. En la Figura 4.10 a) y b) se muestra la proyección correspondiente para PCA y LDA en señales de corriente. Como en los estudios anteriores, se muestra una no buena separabilidad entre clases con el análisis de las señales de corriente, mejora un poco la separación con el estudio en LDA en comparación con PCA que la separación es muy pobre. En LDA se muestra una separación del caso de desbalance con masa excéntrica del resto de clases, las cuales se encuentran mayoritariamente traslapadas.

En la Figura 4.11 se presentan las proyecciones correspondientes a PCA y LDA con un análisis en señales de vibración. La separación de las clases es más notoria en estas proyecciones bidimensionales, a diferencia de las señales de corriente, sin embargo aún existe traslape entre algunos de los casos considerados. Para este caso, en PCA, la separación entre clases es buena, sólo existen algunos puntos de traslape entre las clases correspondientes a el estado de desbalance y el estado de una barra rota con múltiple carga excéntrica.



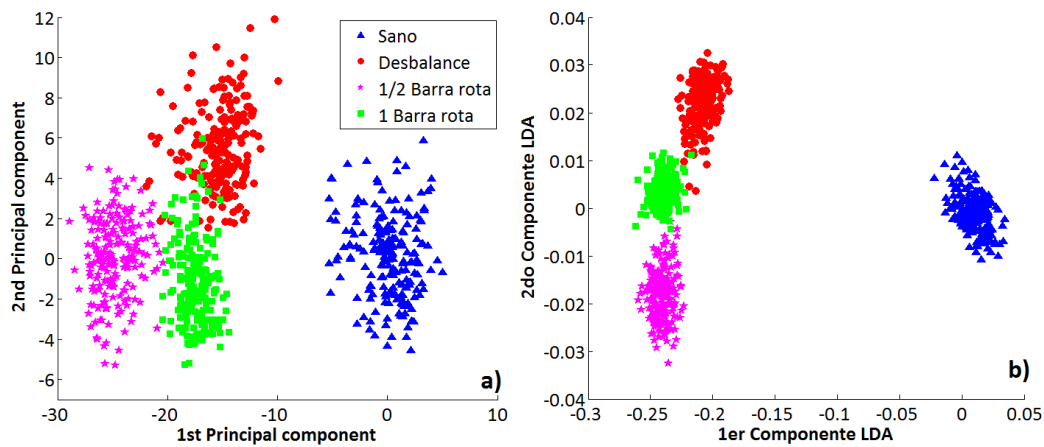
**Figura 4.10:** *Proyecciones de señales de corriente para los casos en estado sano, desbalance, media barra y una barra rota. a) Proyección con PCA, b) Proyección con LDA*

Una manera de dar solución al problema de traslape entre clases es a través de la reducción de indicadores o aumentando el número de indicadores para realizar la proyección obtenida a través de PCA y LDA. Para la primera, que es la reducción de indicadores, se tiene que realizar un estudio exhaustivo y supervisado del valor de la magnitud de cada uno de los coeficientes de los indicadores estadísticos que componen las proyecciones. Se descarta aquellos indicadores que proporcionan poca información representativa, es decir que tienen un valor menor al del resto de indicadores. La otra forma es aumentar el número de indicadores para así maximizar la información de representación, aunque esto también trae problemas de adición de información redundante y no significativa. La alternativa de aumentar el número de indicadores estadístico consiste en hacer una fusión entre los indicadores de corriente y los indicadores de vibración, teniendo así 30 indicadores para realizar la representación a través de PCA y LDA.



**Figura 4.11:** *Proyecciones de señales de vibración para los casos en estado sano, desbalance, media barra y una barra rota. a) Proyección con PCA, b) Proyección con LDA*

En la Figura 4.12 se presenta las proyecciones correspondientes a la fusión de indicadores estadístico-temporal de las señales de corriente y vibración. En 4.12 a) se muestra la proyección para PCA mientras que en 4.12 b) se muestra la proyección usando LDA. Estas muestran que al combinar la información de ambas magnitudes físicas se obtiene una mejoría en las proyecciones que permiten diferenciar mejor entre cada una de las clases. En el caso de PCA aumenta un poco en la dispersión entre clases, en LDA se logra una separación exitosa entre cada clases. Esto facilitará en gran medida la clasificación de los casos al implementar un clasificador.

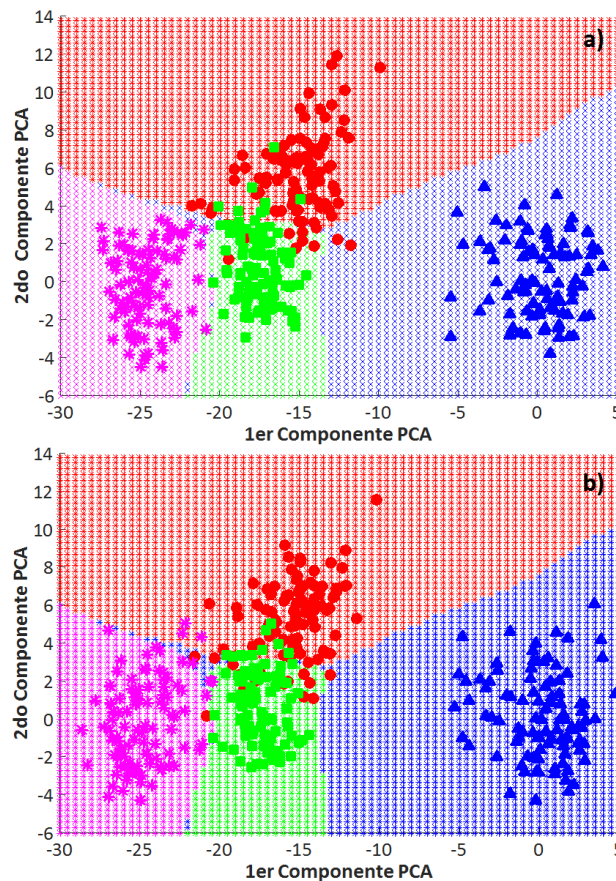


**Figura 4.12:** *Proyecciones de fusión de señales para los casos en estado sano, desbalance, media barra y una barra rota. a) Proyección con PCA, b) Proyección con LDA*

## 4.6. Clasificador Basado en Redes Neuronales

Finalmente, y con el objetivo de cuantificar la clasificación entre los casos considerados, se implementa un clasificador multinivel basado en redes neuronales. Debido a la fusión de magnitudes físicas se obtuvieron proyecciones que permitirán el uso de una estructura simple para la implementación del clasificador, obteniendo buenos resultados sin un uso excesivo de recursos. El clasificador consiste de 10 neuronas en su primera capa, la capa de salida consta de una señal sigmoide como activación con 9 repeticiones para cada fase de entrenamiento. Con la finalidad de obtener resultados estadísticamente significativos el clasificador fue puesto en marcha bajo un esquema de validación cruzada de 5 veces. Para ello los datos que constaban de 200 muestras por condición fueron divididos en 2 partes, cada uno de 100, uno para la parte de entrenamiento de la red neuronal y la otra para la etapa de prueba o comprobación.

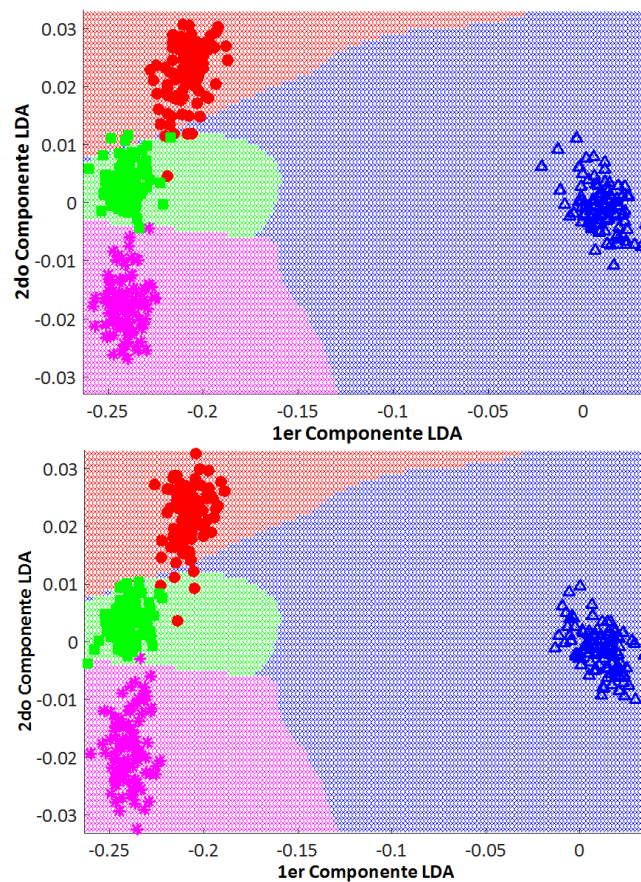
Con la puesta en marcha de la red neuronal se obtienen funciones capaces de clasificar de buena manera las condiciones consideradas. Además es posible realizar una representación visual en donde se delimita cada una de las regiones de decisión pertenecientes a cada clase. En la Figura 4.13 a) y b) se muestran las regiones de decisión y las proyecciones resultantes para el entrenamiento y para la etapa de prueba, respectivamente, correspondientes para el enfoque basado en PCA.



**Figura 4.13:** *Proyecciones de las regiones resultantes de la red neuronal.*

*a) PCA para entrenamiento b) PCA para prueba*

De igual manera se obtiene la representación visual de las fronteras y las proyecciones de cada condición con el enfoque de LDA para el entrenamiento Figura 4.14 a) y para la etapa de prueba Figura 4.14 b). La red neuronal además de proporcionar la función para realizar las fronteras de cada clase, permite obtener las tasas de clasificación para cada uno de los esquemas de validación cruzada.



**Figura 4.14:** *Proyecciones de las regiones resultantes de la red neuronal.*

a) *LDA para entrenamiento* b) *LDA para prueba*

Los radios de radios de clasificación que se obtuvieron para la etapa de entrenamiento en la validación cruzada rondan entre 93 % y 96 % en el caso de PCA y entres 94 % y 97 % para el entrenamiento con LDA. En la etapa de prueba o comprobación los resultados de la clasificación fueron muy similares, se obtuvo una clasificación correcta de entre 91 % y 95 % para el enfoque con PCA y radios de 92 % y 95 % para LDA. En la Tabla 4.3 se muestra el resumen de la matriz de confusión para la etapa de entrenamiento con PCA, mientras que la Tabla 4.4 muestra la matriz de confusión para la etapa de prueba, igualmente con PCA.

**Tabla 4.3:** *Matriz de confusion resultante para el entrenamiento mediante PCA*

Clase asignada	Clase verdadera			
	Sano	Excent	1/2 Brb	1 Brb
Sano	100	2	0	0
Excentricidad	0	88	0	10
1/2 Barra rota	0	0	97	0
1 Barra rota	0	10	3	90

**Tabla 4.4:** *Matriz de confusion para la etapa de prueba mediante PCA*

Clase asignada	Clase verdadera			
	Sano	Excent	1/2 Brb	1 Brb
Sano	100	1	0	0
Excentricidad	0	87	3	10
1/2 Barra rota	0	2	94	1
1 Barra rota	0	10	3	89

En la Tabla 4.5 y la Tabla 4.6 se presentan los resultados resumidos a partir de la matriz de confusión obtenida con la aplicación de la red neuronal para el enfoque con LDA en la etapa de entrenamiento y prueba, respectivamente.

**Tabla 4.5:** *Matriz de confusión resultante para el entrenamiento mediante LDA*

Clase asignada	Clase verdadera			
	Sano	Excent	1/2 Brb	1 Brb
Sano	100	0	0	0
Excentricidad	0	95	0	3
1/2 Barra rota	0	0	98	1
1 Barra rota	0	5	2	96

**Tabla 4.6:** *Matriz de confusión para la etapa de prueba mediante LDA*

Clase asignada	Clase verdadera			
	Sano	Excent	1/2 Brb	1 Brb
Sano	100	0	0	0
Excentricidad	0	94	0	4
1/2 Barra rota	0	0	99	1
1 Barra rota	0	6	1	95

En contraste, los resultados obtenidos con la fusión de indicadores estadísticos de señales de corriente y vibración mejoran significativamente en comparación con los indicadores extraídos de una sola magnitud física. Para la clasificación de las clases tomando solo corriente se obtuvo un radio promedio de 56% en enfoque con PCA y de 65% para LDA, mientras que



para señales de vibración se obtuvieron radios de 82 % para PCA y 75 % con un enfoque de LDA. Se tiene entonces una mejoría significativa de hasta 40 % para PCA y 30 % para LDA en comparación de corriente y fusión de magnitudes. Y una mejoría de 15 % en PCA y 20 % en LDA comparando esquemas de señales de vibración y fusión de magnitudes. La Tabla 4.7 resume los promedios de radios de clasificación obtenidos para señales de corriente, vibración y fusión de corriente y vibración.

**Tabla 4.7:** *Radios de clasificación obtenidos para corriente, vibración y fusión de magnitudes*

	PCA	LDA
Corriente	56%	65%
Vibración	82%	75%
Fusión de magnitudes	96%	95%

---

## Capítulo 5

### Conclusiones

---

## 5. Conclusiones

El estudio realizado presenta una alternativa de análisis de metodologías comúnmente utilizadas en el diagnóstico de fallos o desperfectos dentro de la maquinaria rotativa. El análisis propuesto demuestra la capacidad para caracterizar múltiples fallos en una cadena cinemática por medio del cálculo de características estadístico-temporal aplicadas a dos magnitudes físicas, corriente y vibración.

Mediante el cálculo, combinación y reducción indicadores estadísticos basados en el tiempo, se demostró que se obtienen buenos resultados en la caracterización de diferentes condiciones de operación en una cadena cinemática operada bajo la influencia de una carga excéntrica oscilante. Además, se observó que para algunas condiciones de operación, el análisis basado en vibraciones mejora la representación de las diferentes condiciones, así mismo, con respecto a los métodos, dado que uno busca obtener una alta representabilidad de los datos (PCA) y por otro lado, uno busca una buena proyección de ellos (LDA), se tienen también diferencias significativas a la hora de visualizar los resultados, teniendo una mayor capacidad de discriminación por parte de LDA.

---

La versatilidad de la metodología permite mejorar los resultados ya obtenidos, esto a través de la reducción de indicadores estadísticos o con la combinación de magnitudes físicas, ampliando el número de indicadores a para realizar la representación de los casos de estudio. En ambos casos se obtuvieron buenos resultados y se mejoraron las capacidades de discriminación al aplicar los métodos de reducción de dimensionalidad.

El uso de un algoritmo de clasificación como Redes Neuronales permitió obtener una correcta clasificación de las diferentes condiciones de fallo consideradas, permitiendo la comparación entre usar solo una magnitud física o dos magnitudes físicas. Además proporciona una certeza al obtener un radio de clasificación entre cada clase y no limitarse solo a la proyección visual de los datos.

## 6. Referencias

Abdi, H., Williams, L. J., 2010, Principal component analysis, John Wiley & Sons, Inc. WIREs Comp Stat 2010, 2 433–459.

Breiman, L., Friedman, J., Stone, C. J., Olshen, R.A., 1984, Classification and Regression Trees, Taylor & Francis, Jan 1, 1984, ISBN 0412048418, 9780412048418.

Culbert I. M. and Rhodes W., Using current signature analysis technology to reliably detect cage winding defects in squirrel-cage induction motors, IEEE Trans. Ind. Appl., vol. 43, no. 2, pp. 422–428, Mar./Apr. 2007.

Garcia-Ramirez, A. G., Morales-Hernandez, L. A., Osornio-Rios, R. A., Benitez-Rangel, J. P., Garcia-Perez, A. and Romero-Troncoso, R. J. 2014, Fault detection in induction motors and the impact on the kinematic chain through thermographic analysis. Electric Power Systems Research 114, 1–9.

Henríquez, P. Alonso, J. B., Ferrer, M. A., and Travieso, C. M., 2014. Review of Automatic Fault Diagnosis Systems Using Audio and Vibration Signals. IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 44, no. 5, may 2014.

Jafarian, K., Darjani, M. and Honarkar, Z. 2016, Vibration Analysis for Fault Detection of Automobile Engine Using PCA Technique, 4th International Conference on Control, Instrumentation, and Automation

(ICCIA) 27-28 January 2016, Qazvin Islamic Azad University, Qazvin, Iran.

Mejía Barrón, A., 2015, Análisis De Impedancia Espectral En Motores De Inducción Bajo Modos De Control Escalar Y Vectorial, Tesis de Maestría. Universidad Autónoma de Querétaro.

Nabilah, H.E., Wan K., Talha, K. S., Hazwan M. A., Shahrman A.B., Razlan, Z. M. and Hazry, D., 2015, Recognition of Objects by Grasping Force Using Linear Discriminant Analysis(LDA), IEEE International Conference on Control System, Computing and Engineering, 27 - 29 November 2015, Penang, Malaysia.

Nandi S., Toliyat H. A., and Xiaodong L., Condition monitoring and fault diagnosis of electrical motors—A review, IEEE Trans. Energy Convers., vol. 20, no. 4, pp. 719–729, Dec. 2005.

Ripley, B.D., 1996, Pattern Recognition and Neural Networks, Cambridge University Press, 1996, ISBN 0-521-46086-7.

Saucedo-Dorantes, J. J., Garcia-Ramirez, A. G., Jauregui-Correa, J. C., Osornio-Rios, R. A., Garcia-Perez, A., Romero-Troncoso, R. J., 2014, Reliable methodology for gearbox wear monitoring based on vibration analysis, Industrial Electronics Society, IECON 2014 - 40th Annual Conference of the IEEE.

Saucedo-Dorantes, J. J., Delgado-Prieto, M., Ortega-Redondo, J. A., Osornio-Rios, R. A. and Romero-Troncoso, R. J., 2016, Multiple Fault

---

Detection Methodology Based on Vibration and Current Analysis Applied to Bearings in Induction Motors and Gearboxes on the Kinematic Chain, Hindawi Publishing Corporation Shock and Vibrationm Volume 2016, Article ID 5467643.

Seera, M., Lim, C. P., Ishak, D. and Singh, H., 2012, Fault Detection and Diagnosis of Induction Motors Using Motor Current Signature Analysis and a Hybrid FMM–CART Model, IEEE Transactions On Neural Networks And Learning Systems, Vol. 23, No. 1, January 2012.

ShanKan, M., Tan, A. C.C., Mathew, J., 2015, A review on prognostic techniques for non-stationary and non-linear rotating systems, Mechanical Systems and Signal Processing 62-63 (2015).

Theodoridis S. and Koutrombas K., Pattern Recognition, Ed. Academic Press, 2009.

Yin, S., Ding, S. X., Xie, X. and Luo, H., 2014, A Review on Basic Data-Driven Approaches for Industrial Process Monitoring, IEEE Transactions On Industrial Electronics, Vol. 61, No. 11, November 2014.



Yoshida, K., Inui, M., Yairi, T., Machida, K., Shioya, M., Masukawa, Y., 2008, Identification of Causal Variables for Building Energy Fault Detection by Semi-supervised LDA and Decision Boundary Analysis, IEEE International Conference on Data Mining Workshops (2009).

Wei-Yin, L., 2011, Classification and Regression Trees, 2011 John Wiley

& Sons, Inc. Volume 1.

Zhang, Y., Shi, H., Zhou, X., Zheng, Z., 2015, Vibration Analysis Approach for Corrosion Pitting Detection Based on SVDD and PCA, The 5th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent Systems, June 8-12, 2015, Shenyang, China.

# 13° CONGRESO INTERNACIONAL DE INGENIERÍA



THE STATE UNIVERSITY OF QUERETARO THROUGH THE  
FACULTY OF ENGINEERING

grant the present

to:

**FRANCISCO ARELLANO ESPITIA**



For your participation:

**General Conference**

QUERÉTARO, MEX. MAY 2017.

**Dr. Aurelio Domínguez González**  
Engineering Faculty Principal

**Dr. Gonzalo Macías Bobadilla**  
General Coordinator- CONIIN 2017







# Diagnostic Methodology Based on Extraction of Statistical Indicators for Detection of Bearing Fault in Induction Motors

Francisco Arellano-Espitia,  
Juan José Saucedo-Dorantes,  
Roque Alfredo Osornio-Rios  
HSPdigital, CA-Mecatronica  
Engineering Faculty, Autonomous  
University of Queretaro  
San Juan del Rio 76806, Mexico  
francisco\_arellano\_fae@live.com.mx.  
jsaucedo@hspdigital.org  
raosornio@hspdigital.org

Rene J. Romero-Troncoso  
HSPdigital CA-Telematica  
DICIS, University of Guanajuato  
Salamanca 36885, Mexico  
troncoso@hspdigital.org

**Abstract**— A bearing fault diagnosis method has been proposed based on the calculation of a statistical-time set of features applied to detect different faults in the bearing in induction motors. Vibration signals are taken into account for calculating its statistical-time features and perform the characterization analysis of fault conditions. Then, the features are subjected to a reduction through Principal Components Analysis. Finally a Fuzzy- based classifier is implement to diagnosis of the different status. Analysis were conducted on electrical motor bearings with three different fault categories and several levels of fault severity. The experimental results shown that the proposed methodology cannot only reliably discriminate between different fault categories, but classifier the level of fault severity. Due to the performance of the proposed methodology, this is applicable in different industrial areas.

**Keywords**—*Induction Motors, Fault Diagnosis, Principal Components Analysis, Vibration Measurement.*

## I. INTRODUCTION

**I**NDUCTORS motors influence all areas of modern life at both the domestic and industrial level. The average modern home in the world contains 20-30 electric motors in the range 0-1 kW for clocks, toys, domestic appliances, air conditioning or heating systems. Modern cars use electric motors for windows, windscreen wipers, starting and now even for propulsion in hybrid vehicles. In the industry, water systems are also driven by electrical machines, as are the processes that produce the raw materials for the agricultural, chemical and pharmaceutical industries [1]. Environmental changes and load conditions applied to motors can cause a malfunction and reduce the efficiency of the motors, leading to repair expenses and financial loss due to unexpected downtime. Common faults in induction motors are: 1) air-gap eccentricity;

2) rotor bar damage; 3) bearing damage; and 4) stator winding imbalance [2]. These faults are often progressive and eventually cause more breakdowns inside the machine. A suitable methodology for constant monitoring can perceive the faults as they develop and help identify the cause of faults and prevent subsequent failures.

One of the main flaws to be analyzed is damage to bearings. Within these are three types of flaws to be analyzed: inner race damage, outer race damage and ball damage [2]. Commonly the variables used for the detection of failure in bearings are: vibrations, current measurement and acoustic emission. Some applications that make use of the vibration measurement for the diagnosis of the condition are focused on the diagnosis of pitting corrosion faults in rolling bearings [3]. Also, condition monitoring using vibration analysis is used in hybrid motors and cars in automobile industry for detecting or anticipating faults [4]. Currents analysis are based on calculation of characteristic frequencies in bearings fault, in order to locate the spectral components of the faults [5]. The condition monitoring analysis by acoustic emission can make a reliable assessment of the presence of specific fault condition in an induction motor with a single fault present through the study of a sound signal [6]. In addition to the measurement of these variables, several analyzes are performed as classical spectral analysis (such as fast Fourier transform). Another type of time-frequency analysis that is used is Wavelet transforms [7] and Hilbert transform [8]. Although the methodologies mentioned above are quite reliable in fault detection, these are only useful for the study of a single type of failure in bearings, limiting to study each type of failure separately.

This paper present a methodology based on the extraction of statistical indicators with the objective of making the detection of failures in bearings in induction motors.

In this methodology a (Principal Component Analysis) PCA analysis is used to make a classification of different types of failure in bearings, as well as the classification of different severities of the same damages using vibration signals. The problems in bearings that will be attended are: inner race damage, outer race damage and ball damage. The advantages offered by this methodology is a reliable classification and detection of different failures and different severity of damage, in bearings.

## II. BACKGROUND THEORETICAL

This part deals with the theoretical relationships for the predictable of failures in bearings in induction motors, as well as the tool that is used for the detection of such failures.

### A. Extraction of Fault Frequencies

Bearing faults can be classified according to the location of faults (outer race, inner race and ball) and the type of defect (cyclic or noncyclic).

A single-point (cyclic) defect produces an impact between the ball and the raceway and generates a detectable vibration. Various theoretical frequencies can be calculated such as the inner and outer race element pass frequencies and ball rotational frequency. These vibrations occur are predictable and depend on which surface of the bearing contains the fault, on the geometrical dimensions of the bearing, and on the rotational speed of the rotor  $f_r$ . Such specific vibration frequencies is the follows [9]:

$$\text{Outer race: } f_o = N/2 f_r (1 - d/D \cos(\alpha)) \quad (1)$$

$$\text{Inner race: } f_i = N/2 f_r (1 + d/D \cos(\alpha)) \quad (2)$$

$$\text{Ball: } f_b = N/2d f_r (1 - (d/D)^2 \cos^2(\alpha)) \quad (3)$$

where  $N$  is the number of balls,  $d$  is the ball diameter,  $D$  is the bearing pitch diameter, and  $\alpha$  is the ball contact angle (typically equal to  $0^\circ$ ). Fig. 1 shows the variables in the bearing geometry. For simplicity, the outer and inner race characteristic frequencies can be approximated for most bearings with between 6 and 12 balls by

$$f_o = 0.4 N f_r \quad (4)$$

$$f_i = 0.6 N f_r \quad (5)$$

Another method of detecting bearing faults can be obtained by noting that bearing vibration typically leads to variations in the motor torque which is related to the current drawn by the motor. Thus, the current harmonics at the specific frequencies will be affected by bearing vibration. The current spectrum can also be used to detect bearing failures as follows:

$$\text{Outer race: } f_{\text{current}} = f_s \pm k f_c \quad (6)$$

However, these analyzes usually include information of other damages inside the machine, so it is necessary to eliminate this information with other techniques, such as Wiener filter-based noise cancellation [10] and statistical approaches [11].




Fig. 1. Structure of a ball bearing.

### B. Feature Reduction using PCA

The best way to realize a good classification of faults is by means of a set of features. However, a reduced number of features will not contain enough information to describe and to characterize the machine working conditions. Therefore, the addition of new features is an option to increase the capability of discrimination, and improve the classification performance. However, working with a high-dimensional set of features it could complicate the classification process, since may not offer additional information to the machine condition. In addition to having redundant information, misclassifications can be obtained and have a high computational cost, compromising the proper convergence of the algorithms [12]. For that reason, techniques of feature reduction are implemented in condition monitoring schemes [13]. Mainly, it is possible to remove redundant or non-discriminative features by means of two reduction type of analysis: feature selection and feature extraction.

The implementation of feature selection strategies in condition monitoring schemes is used to preserve the most discriminative characteristic. On the other hand, features characteristic extraction differs in the question of whether a technique is supervised or unsupervised. The main difference between both techniques is the availability of labels to distinguish the different classes. PCA is a well-known and the most common used technique for unsupervised dimensionality reduction and feature extraction [14]. PCA is a mathematical procedure for multivariate analysis using an orthogonal transform to convert a set of observation variables correlated with a set of variable values linearly uncorrelated denominated as principal component. The reduction from the number of variables is not performed by a variable selection, but the generation of new variables by linear combination from the original variables. PCA is based on statistical analysis and even though it does not concern in the separation of different classes, it has advantage in feature extraction due to preserving the variability of the data. Therefore, the use of PCA analysis is useful in the study of the condition to discard redundant information that is not required to detect faults in a system.

## III. DIAGNOSIS PROCEDURE

The proposed methodology for the detection of faults in bearings is composed of the five steps shown in Fig 2. First, the vibration signals are extracted from Case Western Reserve University (CWRU) Bearing Data Center Website [15].

The experimental test bench used in CWRU for testing the different conditions are shown in Fig. 3. It consists of a 2 hp Reliance Electric motor driving a shaft on which a torque transducer and encoder are mounted. Torque is applied to the shaft via a dynamometer and electronic control system [16]. The database has healthy signals, too data sets for rolling element faults and inner and outer race faults, with the outer race faults themselves grouped into three categories according to the fault position relative to the load zone: ‘centred’, ‘orthogonal’ and ‘opposite’.

Second, the feature calculation. Estimate is made a set of 7 significant statistical features. For the calculation, the measurements are taken into account are in the fan-end bearing housing (FE) and on the motor supporting base plate (BA). For each considered measure it is estimated a set of 14 numerical statistical features, 7 statistical features per each vibration signal. The proposed statistical-time features are: maximum value, Root mean square (RMS), skewness, latitude factor, crest factor, kurtosis, and sixth moment. These statistical-time features and their corresponding equations are listed in Table I. Where:  $x$  is the total set of samples,  $n$  the number of samples,  $\bar{x}$  is the mean  $x_k$  each of the samples,  $\sigma$  the standard deviation and SRM corresponds to the value of Square Root Mean.

The third step is the feature extraction. The estimated sets of statistical features representing the different working conditions are subjected to a compression process and extraction of principal components by means of PCA analysis. Through extraction process a final set of new features from the previous estimated sets of statistical features is obtained. The new extracted set of features is projected in a 2-dimensional space allowing a visual interpretation of the considered conditions, facilitating the classification task.

Finally, the last step is the classification where extracted set of features is evaluated under a structure of a Fuzzy-based classifier to implement a diagnosis of the different status.

#### IV. RESULTS AND DISCUSSION

The results shown in this section are obtained by applying the proposed methodology. The application of this methodology is performed under Matlab for the processing of the vibration signals and the classification of the conditions. As it has been mentioned, the analysis was performed by taking the vibration signals from CWRU considering the measurement at two sites in the kinematic chain, in the fan-end bearing housing and on the supporting motor base plate. The available information was obtained at an operating frequency of 12 KHz and consists of ten seconds for each condition considered, then, each one of the acquired signals is segmented in one hundred parts with the objective to generate a set of consecutive samples.

Then, it proceed to perform the calculation of the 7 statistical-time features from each one of the two vibration signals. Then, have fourteen statistical-time features with 100 samples to represent each of the conditions, with the aim of having a better characterization of healthy and failures conditions. These estimated sets of features are then used for extracting a new subset of features.

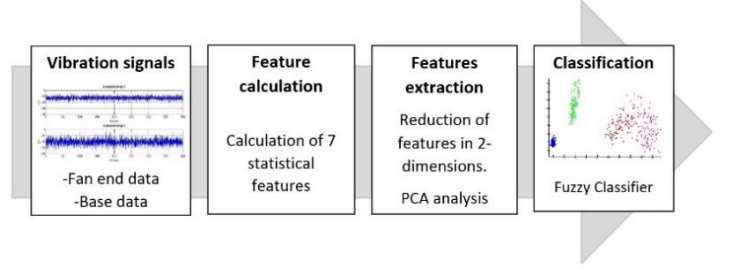


Fig. 2. Proposed diagnosis methodology based on extraction of statistical indicators for detection of bearing fault.

TABLE I  
STATISTICAL TIME-BASED FEATURES

Maximum value	$\hat{x} = \max(x)$	(1)
Root mean square	$RMS = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k)^2}$	(2)
Skewness	$S_k = \frac{E[(x_k - \bar{x})^3]}{\sigma^3}$	(3)
Latitude factor	$LF = \frac{\hat{x}}{SRM}$	(4)
Crest factor	$CF = \frac{RMS}{\hat{x}}$	(5)
Kurtosis	$k = \frac{E[(x_k - \bar{x})^4]}{\sigma^4}$	(6)
Sixth moment	$6thM = \frac{E[(x_k - \bar{x})^6]}{\sigma^6}$	(7)




Fig. 3. Flow chart of the CWRU test bench.

The extraction of the new features is carried out by PCA. The PCA analysis aims to find a new projection in a smaller dimensionality trying to maximize the separation between the considered conditions. Then, it obtain a new subset of extracted features, which contain functions with greater variability and relevant information related to the fault conditions considered. With these sets of features is possible a visual representation of the conditions considered in a two-dimensional space. It should be noticed that the faulty conditions are faced to the healthy condition. Thus, in Fig. 4 are shown the projection of the extracted set of features computed by the PCA considering only one vibration signal in motor supporting base plate.

As a justification for the use of two measurements to improve fault classification, a comparison is made between the sets of features extracted considering a single measurement in FE and the sets of extracted features measured in FE and BA. Then, we proceed to the estimation of the set of seven statistical-time features and then to the projection and extraction of indicators is performed through PCA.

The projected in a 2-dimensional space of the extracted set of features computed by analysis of PCA for measurement in FE are shown in Fig 5.

The main problem that occurs when considering only a measurement of vibration in the kinetic chain is that some of the projections resulting from the considered conditions overlap. As can be seen, the ball fault condition is very near to the fault in outer race. This nearness or overlap in the features extracted from the conditions can lead to a misclassification. Although there is some spreading of some points within the considerations, it should note a greater separation between the classes of faults.

For classification a fuzzy-based classifier is used to diagnose the types of faults and to generate the output classes. When considering two signals of vibration one has a greater separation of the classes, this facilitates in much the classification, for which, a simple structure considered in the classifier allows obtaining good results without an excessive use of computational resources. For a statistically significant result, the classifier is trained and tested under a 5-fold cross-validation scheme. In this scheme for classification, the samples of the conditions are subdivided into two types: data used for training and data used for testing. The original database are composed by 360 samples, 90 samples per condition. For training is used 288 samples, 72 samples per condition; for testing purposes is used 72 samples, 18 samples per condition.

To analyze the performance of the classification proposed by the methodology, we proceed to train and test the same structure of the fuzzy-based classifier, five classification ratios are obtained as a result of the iterations generated by the 5-fold-cross-validation scheme, then, these classification ratios are averaged and a classification ratio for the training is obtained. First, with the extracted sets of features obtained only in the measurement of the motor supporting base. Thus, the classification ratio achieved during the test of the fuzzy-classifier by considering only measurement of the motor supporting base are approximately 73.5%. Meanwhile, when vibrations are used both in supporting base and fan-end bearing housing, have been obtained a classification ratio of 93.6%. Table II summarizes the classification ratios achieved during the test of the fuzzy-classifier of the extracted sets of features by considering only one and two vibration signals.

Therefore, it is shown that the overall classification ratio using two vibration signals is improved by about 20% compared when considering a single vibration signal in the analysis. According to the results obtained, proves the performance of the two vibration signals in the progress of condition monitoring for rolling elements in induction motors.




Fig. 4. Projection of the extracted set of feature computed by the PCA considering a set of statistical features estimated from only one vibration signal.




Fig. 5. Projection of the extracted set of feature computed by the PCA considering a set of statistical features estimated from two vibration signals.

TABLE III  
CLASSIFICATION RATIOS OBTAINED DURING THE TEST OF THE FUZZY-CLASSIFIER

<i>Number of vibration signals</i>	<i>1 vibration signal</i>	<i>2 vibration signals</i>
Classification ratios achieved	73.5%	93.6%

## V. CONCLUSIONS

A bearing fault diagnosis approach has been developed based on vibration signals using the calculation of the 7 statistical-time features: maximum value, Root mean square, skewness, latitude factor, crest factor, kurtosis, and sixth moment, also, the feature extraction by PCA. The feature extraction are then presented for fault classification. For comparison, used two vibration signals versus only one vibration signal. The experimental results indicate that Fuzzy-based classifier can obtain a higher diagnostic accuracy when is used two vibration signals than only one vibration signal, the accuracy increases significantly to 20%.



Four different conditions have been considered, including the healthy and faulty states. The experimental results show that the proposed methodology is suitable to be applied for fault diagnosis of bearings in induction motor. Further, some perspectives of this work is to expand the classification analysis for other types of kinetic chain faults.

#### REFERENCES

- [1] "United States Industrial Electric Motor Systems Market Opportunities Assessment." U.S. Dept. of Energy, Washington, DC, USA, 1998.
- [2] E. T. Esfahani, "Multisensor wireless system for eccentricity and bearing fault detection in induction motors," *IEEE/ASME Transactions on Mechatronics*, vol. 19, no 3, pp. 818-826, 2014
- [3] K. Zhang, Y., Shi, H., Zhou, X., Zheng, Z., 2015, "Vibration Analysis Approach for Corrosion Pitting Detection Based on SVDD and PCA," *The 5th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent Systems*, June 8-12, 2015, Shenyang, China.
- [4] K. Jafarian, M. Darjani, and Z. Honarkar, 2016, "Vibration Analysis for Fault Detection of Automobile Engine Using PCA Technique," 4th International Conference on Control, Instrumentation, and Automation (ICCIA) 27-28 January 2016, Qazvin Islamic Azad University, Qazvin, Iran.
- [5] J. J. Saucedo-Dorantes, M. Delgado-Prieto, J. A. Ortega-Redondo, R. A. Osornio-Rios and R. J. Romero-Troncoso, 2016, "Multiple Fault Detection Methodology Based on Vibration and Current Analysis Applied to Bearings in Induction Motors and Gearboxes on the Kinematic Chain," *Hindawi Publishing Corporation Shock and Vibration* Volume 2016, Article ID 5467643.
- [6] A. G. Perez, R. J. Troncoso, E. C. Yopez, R. O. Rios, and J. L. Martinez, "Application of high-resolution spectral-analysis for identifying faults in induction motors by means of sound," *J. Vib. Control*, vol. 18, no. 11, pp. 15851594, 2012.
- [7] K. I. Rodopoulos and I. A. Antoniadis, "Instantaneous Fault Frequencies Estimation in Roller Bearings Via Wavelet Structures," *Journal of Sound and Vibration* 383(2016) 446463, July 2016.
- [8] L. Leh-Sung, K. Jong-Hyun, L. Willey and L. Sun-Kyu, "An Approach Based on Wavelet Packet Decomposition and HilbertHuang Transform (WPDHHT)for Spindle Bearings Condition Monitoring," *Mechanical Systems and Signal Processing* 33 (2012) 197211, July 2012.
- [9] Bo L., Mo-Yuen C., Yodyium T. and Hung J. C. "Neural-Network-Based Motor Rolling Bearing Fault Diagnosis," *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, October 2000.
- [10] W. Zhou, T. Habetler, and R. Harley, "Bearing fault detection via stator current noise cancellation and statistical control," *IEEE Trans. Ind. Electron.*, vol. 55, no. 12, pp. 42604269, Dec. 2008.
- [11] F. Immovilli, M. Cocconcelli, A. Bellini, and R. Rubini, "Detection of generalized-roughness bearing fault by spectral-kurtosis energy of vibration or current signals," *IEEE Trans. Ind. Electron.*, vol. 56, no. 11, pp. 47104717, Nov. 2009.
- [12] X. Wan, D. Wang, P. W. Tse, G. Xu, Q. Zhang, "A critical study of different dimensionality reduction methods for gear crack degradation under different operating conditions," *Measurement*, vol. 78, pp. 138-150, 2016.
- [13] F. Li, J. Wang, M. K. Chyu and B. Tang, "Weak fault diagnosis of rotating machinery based on feature reduction with Supervised Orthogonal Local Fisher Discriminant Analysis," *Neurocomputing*, vol. 168, pp. 505-519, 2015.
- [14] R. H. Cunha Palacios, A. Goedtel, W. F. Godoy and J. A. Fabri, "Fault identification in the stator winding of induction motors using PCA with artificial neural networks," *Journal of Control, Automation and Electrical Systems*, vol4, no. 20, 2016.
- [15] Case Western Reserve University Bearing Data Center Website <http://csegroups.case.edu/bearingdatacenter/home>.
- [16] W. A. Smith, R B. Randall "Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study," *Mechanical System and Signal Processing* 64-65 , 2015.



# *Statistical data fusion as diagnosis scheme applied to a kinematic chain*

Franciso Arellano-Espitia,  
Juan J. Saucedo-Dorantes,  
Roque A. Osornio-Rios  
HSPdigital CA-Mecatronica  
Engineering Faculty,  
Autonomous University of  
Queretaro San Juan del Rio,  
76806, Mexico  
jsaucedo@hspdigital.org,  
raosornio@hspdigital.org

Miguel Delgado-Prieto,  
Jesús A. Cariño-Corrales  
MCIA Department of Electronic  
Engineering, Technical  
University of Catalonia (UPC)  
Barcelona, 08034, Spain  
miguel.delgado@mcia.upc.edu,  
jesus.carino@mcia.upc.edu

Rene J. Romero-Troncoso  
HSPdigital CA-Telematica  
DICIS, University of Guanajuato  
Salamanca, 36885, Mexico  
troncoso@hspdigital.org

**Abstract**—In the modern industry framework, the application of condition monitoring schemes over electromechanical systems is being subjected to demanding requirements. Industrial electrical machinery implies the consideration of an electric motor, but also, gearboxes, shafts and couplings among others, resulting in complex kinematic chains. Such electromechanical configurations increase the risk of multiple faults coexistence and overlapping of corresponding effects in the considered physical magnitudes. Currently, the massive digitalization of industrial assets allows the investigation towards multiple monitoring strategies capable of emphasize deviations over the nominal system operation from different domains. In this regard, the proposed study presents the analysis of the diagnosis capabilities resulting from a high-dimensional statistical time-domain data fusion approach. First, multiple statistical time features are estimated from the available physical magnitudes, in this case, stator currents and vibrations. Second, two linear feature reduction techniques, such as principal components and linear discriminant analysis, are applied and compared. Third, a neural network based hierarchical structure is implemented for pattern recognition. The performance of the diagnosis scheme is compared with classical characteristic fault frequencies procedures. The study of the considered methodology is carried out over a kinematic chain driven by an induction motor under two fault scenarios, broken rotor bar and load unbalance.

**Keywords**—*condition monitoring; feature estimation; feature reduction; induction motor; linear discriminant analysis; multiple faults; neural networks; principal component analysis; stator currents; vibrations.*

## I. INTRODUCTION

A great deal of industrial applications are supported by the transformation of electrical to mechanical energy through electric machines, which, nowadays, are mostly based on asynchronous induction motors (IM). The IM represent the most common rotating electrical machines used in industry due to its robustness and competitive cost [1]. For this reason, their use is considered in multiple electromechanical industrial applications, in which gearboxes, shafts, couplings, external bearings and others mechanical elements complete the rotary or

reciprocating operation. However, despite of its characteristics, the appearance of unexpected faults may occur at any time due to the wear and tear of their components, causing undesired breakdowns that affect the productivity and, consequently, the economic viability in the industry. In this regard, the digitalization of the industrial assets represents, currently, a generalized strategy in order to evolve towards a more efficient and competitive sector. A variety of services enhanced by such connectivity are revealed, as new condition-based maintenance strategies, which involves high-performance monitoring and information-fusion procedures to determine the optimum maintenance actions.

Indeed, condition monitoring approaches based on data-driven methods, capable of fault detection during machinery operation, are playing an important role leading to increase industrial equipment availability [2-3]. However, although a great deal of data-driven diagnosis methods have been proposed to identify the appearance of faults in electromechanical systems with significant results, dealing with kinematic chain monitoring, the advantages in front of classical characteristic fault frequencies analysis is not commonly analysed.

The detection and identification of kinematic chain conditions present new challenges in the modern industry framework, where multiple causes of faults are expected to be recognized during the regular operation. Such requirement represents a serious issue to allow a practical implementation of condition monitoring strategies, since the effects of different faults could be hidden or overlapped among them and, then, false negatives may arise. In this regard, fusion information strategies, based on the combination of different physical magnitudes by means of data-driven methodologies, represent the most promising approaches in order to reveal characteristic patterns related with different fault conditions [4-5].

The consideration of stator current or vibration as informative physical magnitudes for condition monitoring represent the most preferred and accepted approaches in the related literature [6-7]. In order to consider improved characterization of such signals, the numerical feature set is extended to additional statistical time-domain, frequency

domain and, also, time-frequency domain. However, although fast Fourier transform and Cohen's class time-frequency distributions have been successfully applied in multiple studies, the simplicity and low computational cost of the statistical time-domain features, represent an interesting characterization potential dealing with uneven industrial environments and operating conditions [8-9].

The estimation of a high-dimensional set of numerical features from the available physical magnitudes and the analysis' domains considered, represents a common strategy to increase the available information and the diagnosis accuracy [10]. However, dimensionality reduction procedures must be applied to avoid low fault diagnosis performances and overfitting responses of the classification algorithms [11]. In this regard, classical techniques of dimensionality reduction have been integrated in condition monitoring schemes; for instance, principal component analysis (PCA), and linear discriminant analysis (LDA), are the main techniques used for reducing high dimensional sets of features and highlight characteristics fault patterns [12]. Thus, pattern learning algorithms are considered for a posterior recognition of similarities during a new measurement assessment. In this regard, although different classifiers can be applied, the Neural Networks (NN), as data-driven self-adaptive information processing methods inspired in biological systems, represents the most commonly applied technique in the literature [13].

Thereby, the contribution of this work lies in the study of a fault identification scheme based on statistical data-fusion, and the analysis of the resulting diagnosis performance considering different physical magnitudes and feature reduction techniques. The diagnosis' results are obtained from a hierarchical structure of neural networks, which allows to obtain the condition of the kinematic chain but also the corresponding membership probability. The characterization capabilities of the statistical-time domain features is discussed in regard with classical fault frequencies analysis approaches. A set of experiments acquired from a kinematic chain is used as study's framework. Specifically, two different fault conditions are considered in single and combined mode, that is, broken rotor bar and load unbalance.

This paper is structured as follows. Section II describes the basis of the statistical time-domain data-driven approaches for condition monitoring. Section III describes the proposed methodology under study. The experimental tests to analyse and compare the method performance are presented, first, in Section IV, and discussed later in Section V. Conclusions are summarized, finally, in Section VI.

## II. STATISTICAL DATA-DRIVEN DIAGNOSIS

Although different information fusion levels can be considered for data-driven diagnosis procedures, i.e. signal-level or classification-level, dealing with kinematic chain condition monitoring, the feature-level represents the most appropriate, since multiple numerical fault indicators have been studied as suitable fault indexes in the related literature [14-15]. In this regard, time, frequency and time-frequency domains are the three feature estimation approaches widely applied during the physical magnitude characterization process. Although techniques based on frequency and time-frequency domains have been widely applied with outstanding results,

most of these techniques requires specific knowledge of the machinery characteristics to determine the expected faults effects over the resulting physical magnitudes frequency distributions. The characteristic fault frequencies approaches offer, in general, higher sensitivity to fault occurrences compared with statistical time features. However, such superiority in detection requires, often, particular operating conditions supervision procedures to analyse the steadiness of the operation when applied on industrial environments. In this regard, the consideration of statistical time-domain features represents a performing alternative and a good trade-off between computational simplicity and characterization capabilities. Such feature-level fusion scheme is supported on the estimation of a high-dimensional set of numerical features from the available physical magnitudes.

Considering  $x_k$  as the  $k$ th sample of the acquired measurement of  $n$  total samples, the classical set of statistical-time features, successfully used in different studies for fault detection in electrical motors, are shown in Table I.

TABLE I. STATISTICAL TIME-DOMAIN FEATURES

Mean	$\bar{x} = \frac{1}{n} \cdot \sum_{k=1}^n  x_k $
Maximum value	$\hat{x} = \max(x)$
Root mean square	$RMS = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k)^2}$
Square root mean	$SRM = \left(\frac{1}{n} \cdot \sum_{k=1}^n \sqrt{ x_k }\right)^2$
Standard deviation	$\sigma = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2}$
Variance	$\sigma^2 = \frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2$
RMS Shape factor	$SF_{RMS} = \frac{RMS}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$
SRM Shape factor	$SF_{SRM} = \frac{SRM}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$
Crest factor	$CF = \frac{\hat{x}}{RMS}$
Latitude factor	$LF = \frac{\hat{x}}{SRM}$
Impulse factor	$IF = \frac{\hat{x}}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$
Skewness	$S_k = \frac{E[(x_k - \bar{x})^3]}{\sigma^3}$
Kurtosis	$k = \frac{E[(x_k - \bar{x})^4]}{\sigma^4}$
Normalized fifth moment	$5thM = \frac{E[(x_k - \bar{x})^5]}{\sigma^5}$
Normalized sixth moment	$6thM = \frac{E[(x_k - \bar{x})^6]}{\sigma^6}$

Although a higher number of statistical time-domain features could increase the fault detection and identification capabilities, inevitably redundant and non-significant information is generated. In this regard, feature extraction

methods are classically considered to extract some form of combination of all or a subset of the initial features, in order to result in a higher informative and reduced feature set contained most of the original information. This kind of techniques are often referred as feature fusion due to its significant reduction capabilities. Linear based techniques predominate in this stage because, when the underlying distributions of the characterized conditions are roughly linearly separable, a small number of samples usually suffice to perform the projection of high dimensional data into a lower dimensional subspace.

Principal component analysis is one of the most commonly used technique for unsupervised dimensionality reduction [16]. The application of PCA generates a new set of features, called principal components. Each principal component is a linear combination of the original features. PCA aims to find the linear projections that best capture the variability of the data and all the principal components are orthogonal to each other, therefore, there is not redundant information. Thus, considering a data matrix  $X \in \mathbb{R}^{N \times D}$  of  $N$  sample rows and  $D$  feature columns that are normalized to zero mean, with mean values vector  $\mu$ , the projections of the observations in  $X$  into a lower dimensional space,  $d$ , can be represented as follows:

$$T = X P \in \mathbb{R}^{D \times d} \quad (1)$$

where the loading matrix  $P$  contains in columns the right singular vectors of  $X$ . Then, selecting the columns of the loading matrix  $P \in \mathbb{R}^{D \times d}$ , which correspond to the loading vector linked with the first  $d$  singular values, the corresponding lower dimensional space is reached.

Supervised feature extraction techniques present a different approach. Linear discriminant analysis is one of the most well-known supervised techniques for linear dimensionality reduction in multi-class problems [17]. LDA aims to find projections in a low-dimensional representation with the most discriminant information attempting to maximize the linear separation between data points belonging to different classes.

Linear discriminant analysis uses the within-class scatter matrix,  $S_w$ , to evaluate the compactness within each class and the between-class scatter matrix,  $S_b$ , to evaluate the separability of different classes. The goal of LDA is to find a linear transformation matrix,  $W \in \mathbb{R}^{D \times d}$ , mapping the original  $D$ -dimensional space onto a reduced  $d$ -dimensional feature space with  $d < D$ , for which the between-class scatter matrix is maximized, whereas the within-class scatter matrix is minimized.

Being again  $X$  be the data set; each  $x_i$  belongs to a class  $c_i = \{1, 2, \dots, c\}$ . Let  $l_i$  be the number of data points in the  $i$ th class and  $l$  be the number of data points in all classes. Then, the between-class scatter matrix,  $S_b$ , and the within-class scatter matrix, are defined as:

$$S_b = \sum_{i=1}^c l_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2)$$

$$S_w = \sum_{i=1}^c \sum_{x_i \in c_i} l_i (x_i - \mu_i)(x_i - \mu_i)^T \quad (3)$$

where  $\mu_i = 1/l_i \sum_{x_i \in c_i} x_i$  is the mean of the data points in the  $i$ th class, and  $\mu = 1/l \sum_{i=1}^l x_i$  is the mean of the data points in all classes.

Dimensionality reduction procedures are applied in order to avoid low fault diagnosis performances and overfitting responses of the condition monitoring schemes. Different dimensionality reduction approaches, leads to different reduced sets of features that may facilitate the patterns classification. In this regard, the classification algorithms play an important role in such statistical data-driven condition monitoring schemes to accomplish with the expected performances. Neural networks represent the most used classifiers. In this regard, a multilayer neural network structures have been used widely to classify the considered conditions represented by the final feature set.

### III. METHOD

The proposed multi-fault diagnosis scheme under study is composed of four steps as depicted in Fig. 1. First, signal conditioning and acquisition is carried out over vibration and stator current signals. Second, the estimation of the fifteen statistical-time-based features shown previously in Table I, is done over each signal. Fourth, the study of two high-dimensional feature reduction methods, that is, principal component and linear discriminant analyses, is carried out. Thus, fourth, a NN based classification structure is performed, where the fault diagnosis and corresponding probability value is obtained.

The resulting performance of the considered scheme is analysed in front of some variants of the methodology. Thus, the effects of consider a single physical magnitude, that is stator current or vibrations, in front of the consideration of both information sources is analysed. Also, the PCA and LDA resulting projections are compared.




Fig. 1. Proposed diagnosis methodology based on hybrid feature reduction for the detection of multiple faults in electromechanical systems.



In this work, three different kinematic conditions have been considered to be evaluated: healthy (HLT), broken rotor bar (BRB), and load unbalance (LUN). Two severity degrees are considered in case broken rotor bar: half broken rotor bar ( $\frac{1}{2}$  BRB), and one broken rotor bar (1 BRB). Also, two severity degrees are considered in case of load unbalance: 5% of mass deviation (5LUN), and 10% of mass deviation (10LUN), both regarding a coupled disk in the rotational axis. For each considered condition, 250 measurements have been acquired. Each measurement corresponds to 1 second of the machine operation.

#### IV. EXPERIMENTAL TEST BENCH

The experimental test bench used to analyse the method performance is based on a kinematic chain. The electromechanical system consists of a 1492-W three-phase induction motor, model WEG00236ET3E145T-W22 with one pair of poles and 10 rotor bars, managed from a variable frequency driver (VFD). The IM output shaft drives two gearbox that are sequentially connected, the first gearbox is a 10:1 ratio gearbox model NORD SK-1SI50-1, and the second gearbox is a 4:1 ratio gearbox model BALDOR GCF4X01AA, which in turns, is linked to a DC generator model BALDOR-CDP3604 used as a mechanical load. Moreover, in between the second gearbox and the mechanical load, an aluminium disk with 20 centimetres of radius is installed to produce the oscillating load condition. The complete experimental test bench is shown in Fig. 2.




Fig. 2. Experimental test bench

The mechanical vibrations in the perpendicular plane of the output gearbox rotating axis are measured with an accelerometer model LIS3L02AS4. Besides vibration signals, an IM stator current is acquired using Hall-effect current sensors model L08P050D15 from Tamura Corporation, this Hall-effect sensor is installed in the power supply wires between the VFD and the IM. The data acquisition system (DAS), corresponds to 12-bit sampling analogue-to-digital converters model ADS7841. The DAS is a proprietary low-cost design based on field programmable gate array technology. The vibrations and stator current signals are acquired using a sampling frequency of 3 kHz and 4 kHz, respectively. As

mentioned, two different fault conditions are considered, that is, broken rotor bar and unbalance load. The different severities of BRB faults are induced artificially by damaging two IM rotor elements, and these faults were produced by drilling both rotor bar elements resulting in a hole with 6 mm of diameter in; thus, the rotor bar element which represents the  $\frac{1}{2}$  BRB fault is drilled with a hole that has a depth of 3 mm that corresponds mostly to the 22% of the transversal section of the rotor bar, and the rotor bar element that simulates the 1 BRB fault is drilled with a hole with a depth of 14 mm drilling that is completely the transversal section of the rotor bar.

During the experimental evaluation the healthy IM rotor element is iteratively replaced by the damaged elements, besides, the IM is driven at the operating frequency of 60Hz producing an averaged rotating speed of 3580.2 rpm in the IM output shaft, resulting in a slip,  $s$ , of 0.0055. Regarding the different oscillating load conditions, these are also artificially produced by attaching masses in the tangential line of the disk circumference, approximately 5% and 10% of mass deviation. In Fig. 3(a) and Figure 3(b) are shown the different severities of BRB evaluated in the IM, and in Figure 3(c) is show the attached mass in the disk.




Fig. 3. Arrangement of the different faults produced in the experimental test bench. (a)  $\frac{1}{2}$  broken rotor bar. (b) 1 broken rotor bar. (c) Load unbalance.

#### V. EXPERIMENTAL RESULTS

Previous to the consideration of the methodology under study, classical frequency analysis has been carried out over the stator current and vibration signals, following the expected characteristic frequencies referenced in multiple studies. In this regard, mechanical non-ideals in the motor are usually reflected in variations over the rotor rotational frequency,  $f_r$ . Thus, considering the stator current, the use of gearboxes, and the influence of load oscillations induces  $f_g$  components given by

$$f_g = f_s \pm kf_r / g_r \quad (4)$$

where  $f_s$  is the supply fundamental frequency,  $k$  is a positive integer and  $g_r$  is the gearbox ratio. In a similar way, asymmetry in the rotor cage due to broken bars produce twice the slip frequency sidebands of the fundamental component in the stator current,  $f_{brb}$ , given by [18],

$$f_{brb} = (1 \pm 2ks) f_s \quad (5)$$

Some of these characteristic frequencies are shown in Fig. 4 under the considered experimental scenarios analysed in this study. Thus, in Fig. 4(a), the  $f_g$  modulated over the  $f_s$  due to the

two gear stages can be seen in form of sidebands @  $\pm 1.5$  Hz approx. and  $\pm 6$  Hz approx.. The increase of such frequencies in presence of load unbalance can be detected in Fig. 4(b). The expected  $f_{brb1}$  appear also in Fig. 4(c) under a broken rotor bar fault condition. Finally, all characteristic frequencies are detectable when combined conditions coexists, as shown in Fig. 4(d).

Considering vibration signal analysis, the characteristic frequencies due to gearboxes implies the rotational frequency,  $f_r$ , and also gear mesh frequencies,  $f_{gm}$ , resulting from the number of gear teeth,  $Z$ , and its respective running frequency.

$$f_{gm} = f_r \cdot Z \quad (6)$$

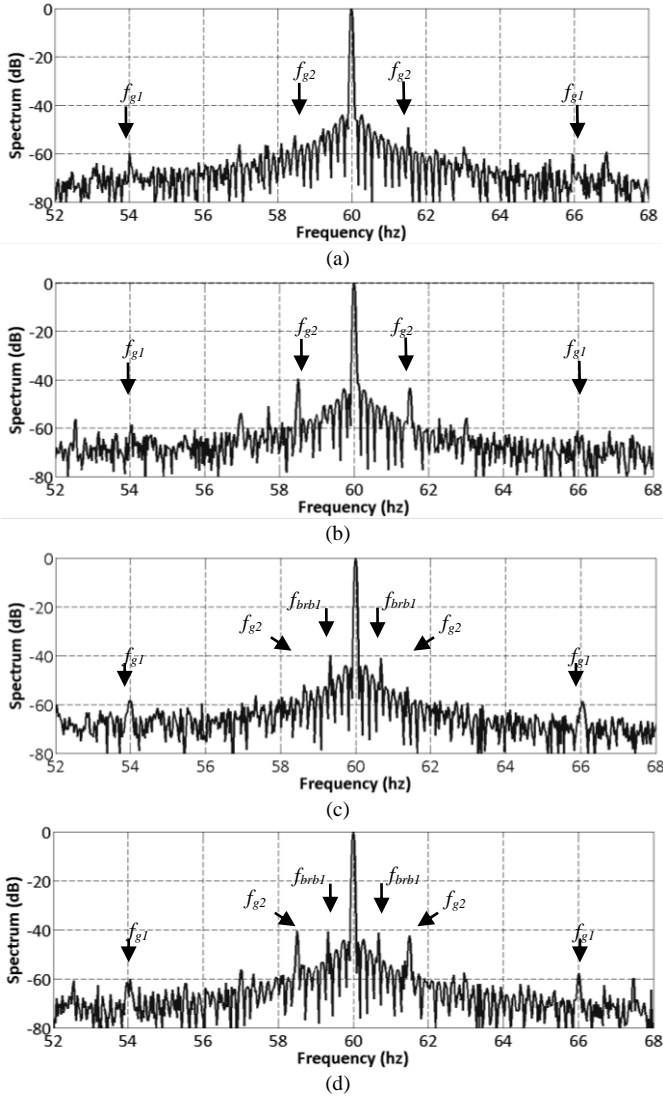


Fig. 4. Frequency contents of stator current phase  $a$  under different kinematic chain conditions. (a) Healthy motor. (b) Healthy motor and 10% of unbalanced load. (c) 1 broken rotor bar. (d) 1 broken rotor bar and 10% of unbalanced load.

In vibration spectrum, also, a fault related to rotor as broken rotor bar will result in increased vibration amplitude at the rotation frequency  $f_r$  and its sidebands

$$f_{brb2} = f_r \pm f_p \quad (7)$$

where  $f_p$  is the pole pass frequency defined as

$$f_p = (f_{sync} - f_r) \cdot P \quad (8)$$

with  $P$  being number of poles and  $f_{sync}$  being synchronous speed [19]. However, the consideration of kinematic chains with double-staged gearbox makes difficult their identification due to overlapping among characteristic frequencies.

Thus, as can be seen in Fig. 5(a), the corresponding sidebands @  $\pm 1.5$  Hz approx. and  $\pm 6$  Hz approx., resulting from the gearbox effects, are clearly visible from the initial healthy condition. Such components shown different amplitudes depending on the fault condition, as can be seen in Fig. 5(b), Fig. 5(c) and Fig. 5(d).

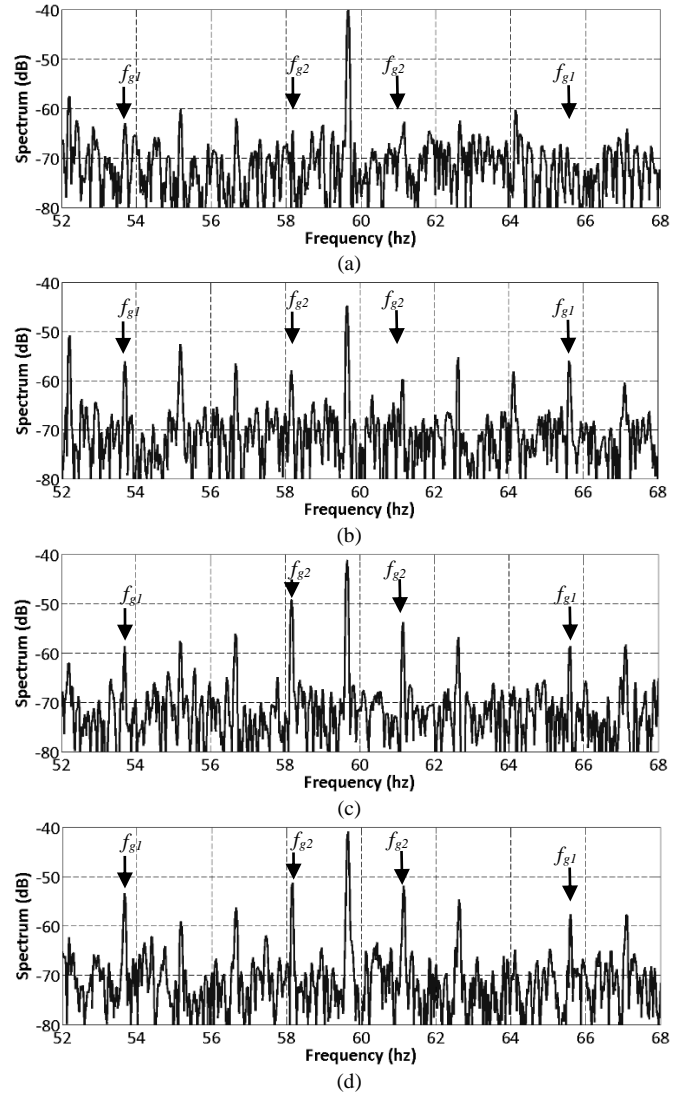


Fig. 5. Frequency contents of vibration axis  $x$  under different kinematic chain conditions. (a) Healthy motor. (b) Healthy motor and 10% of unbalanced load. (c) 1 broken rotor bar. (d) 1 broken rotor bar and 10% of unbalanced load.

However, the expected  $f_{brb2}$  as  $\pm 0.76$  Hz sidebands, are not easily detectable. Also, broken rotor bar should result in increased vibration amplitudes at rotor bar pass frequency  $f_{rbp}$

$$f_{rbp} = f_r \cdot N_r \quad (9)$$

and its sidebands modulated at two times the frequency of the power source  $f_s$

$$f_{rbpsb} = f_{rbp} \pm f_s \quad (10)$$

where  $N_r$  is the number of rotor bars. However, the effect of gear mesh frequencies makes undistinguishable such components.

The statistical time-domain characterization in front of the same kinematic conditions is analysed, first, by means of PCA. In Fig. 6, the resulting projections into a 2-dimensional space from the stator current estimated features, Fig. 6(a), vibration estimated features, Fig. 6 (b), and estimated features from both physical magnitudes, Fig. 6(c), are shown. It can be seen that, stator current features from a variance preservation principle cannot assist during the condition identification.

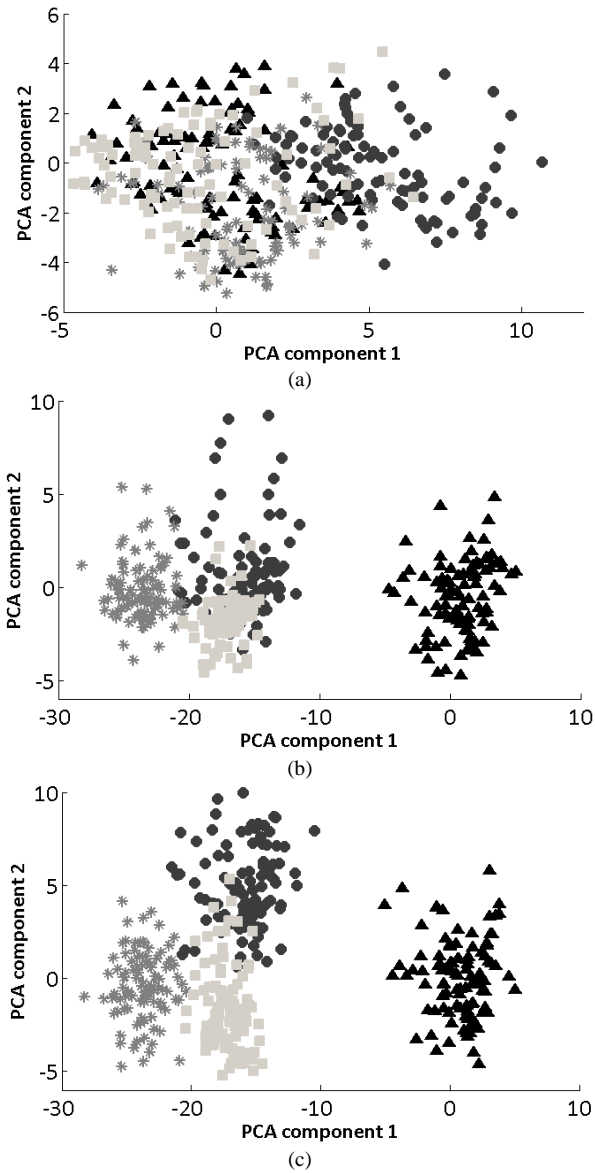


Fig. 6. Resulting 2-dimensional principal component analysis considering:  $\frac{1}{2}$  broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, \*, Healthy @ 5% load unbalance and @ 10% load unbalance, •, 1 broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, ■, and Healthy @ no load unbalance, ▲. (a) Stator current analysis. (b) Vibration analysis. (c) Stator current and vibration analysis.

However, the vibration features following the same variance preservation principle exhibits some characteristic patterns that allow the identification of the considered conditions. This effect is improved when combining both stator current and vibration sources of information.

Next, the statistical time-domain characterization in front of the same kinematic conditions is analysed by means of LDA. In Fig. 7, the resulting projections into a 2-dimensional space from the stator current estimated features, Fig. 7(a), vibration estimated features, Fig. 7 (b), and estimated features from both physical magnitudes, Fig. 7(c), are shown. It can be seen that, stator current features from a discriminant optimization principle exhibit a better performance than the variance preservation variant.

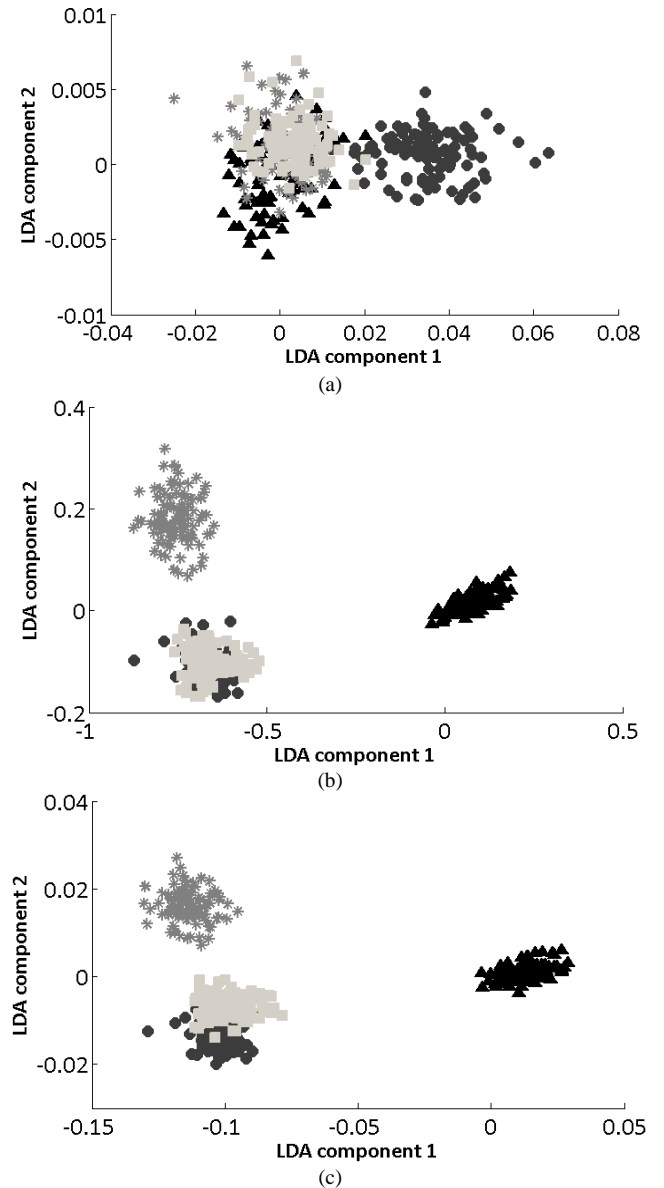


Fig. 7. Resulting 2-dimensional linear discriminant analysis considering:  $\frac{1}{2}$  broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, \*, Healthy @ 5% load unbalance and @ 10% load unbalance, •, 1 broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, ■, and Healthy @ no load unbalance, ▲. (a) Stator current analysis. (b) Vibration analysis. (c) Stator current and vibration analysis.

The vibration features following the same discriminant optimization principle allow the identification of most of the considered conditions. The discrimination effect is improved again when combining both stator current and vibration sources of information.

The application of dimensionality reduction techniques results in the projection of the data in new axis composed by a weighted relation of the original feature set. In this regard, it is possible to analyse the most significant statistical time-domain features identified by the techniques in order to inspect their characterization capabilities. Thus, for examples, dealing with stator current signal, one of the most significant features corresponds to the crest factor, that is, the ratio of the peak value to the rms value. In general, as any signal exhibits peaks, its crest factor increases indicating that the peak value is a larger than the rms value. Values of crest factor, previous normalization, are in the range of 1 to 2, which is common in electrical machinery analysis, however, significant increases may indicate a problem [20]. In the analysed case study, as it is shown in Fig. 8(a), the load unbalance produces sharp peaks in the stator current signal that allows its identification in regard with the other conditions. Another significant statistical time-domain features for stator current signal are the max value, the rms and the standard deviation. Dealing with the vibration signals, one of the most significant features corresponds to the skewness, that is, a measure of the asymmetrical spread of the signal about its mean value. This feature indicates the asymmetry of the probability density function, meaning the deviation degree from the symmetry of a distribution. If the calculated value of skewness is negative the curve is shifted to the left and if that value is positive the curve is shifted for the right. If it is null, the curve is perfectly symmetric.




Fig. 8. Significant statistical features identified by dimensionality reduction techniques over the considered conditions:  $\frac{1}{2}$  broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, \*, Healthy @ 5% load unbalance and @ 10% load unbalance, •, 1 broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, ■, and Healthy @ no load unbalance, ▲. (a) Crest factor of stator current. (b) Skewness of vibration.

In the analysed case study, as it is shown in Fig. 8(b), all three fault condition exhibit skewness values lower than 0 in the vibration signal that allows the detection of deviations during the operation. Another significant statistical time-domain features for vibration signal are the rms, the kurtosis and the crest factor.

Following the analysed method, the classification stage follows, the NN-based classifier has been configured with 10 neurons in the hidden layer, besides a logistic sigmoid function has been used as output activation function and 100 epochs are considered for training using the back-propagation rule. For checking the performance of the proposed methodology, a test set has been considered. The resulting decision regions considering PCA and LDA, can be seen in Fig. 9(a), and Fig. 9(b), respectively.

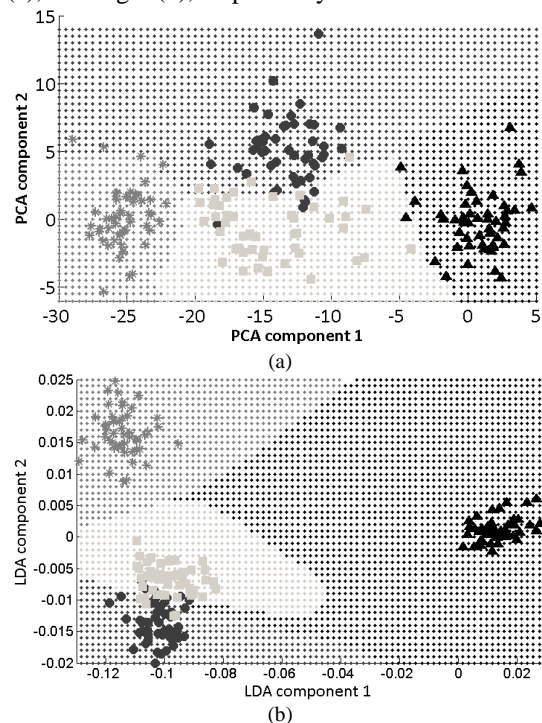


Fig. 9. Resulting neural network classification map from a 2-dimensional principal component analysis considering a test set:  $\frac{1}{2}$  broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, \*, Healthy @ 5% load unbalance and @ 10% load unbalance, •, 1 broken rotor bar @ no load unbalance, @ 5% load unbalance and @ 10% load unbalance, ■, and Healthy @ no load unbalance, ▲. (a) PCA analysis. (b) LDA analysis.

The classification ratios for the test sets are approximately 90% for PCA, and 88% for LDA, as it is shown in Tables II and II, respectively. It can be noticed that the UNB condition tends to confused with 1 BRB condition in both approaches. Even though sometimes the HLT condition is classified as a faulty one, there is possibility for checking the probability membership.

In addition to the resulting class, the proposed NN also offers the corresponding diagnosis probability due to the sigmoid function used as an activation function of the last NN layer. In this case, it must be noticed that the misclassified

samples shown an average probability value of 60%, that is a significant low value.

TABLE II. RESULTING NN CONFUSION MATRIX CONSIDERING PCA DIMENSIONALITY REDUCTION

Assigned Class	True Class			
	HLT	UNB	1/2 BRB	1 BRB
HLT	50	0	0	0
UNB	0	45	0	5
1/2 BRB	0	0	50	0
1 BRB	0	5	0	45

TABLE III. RESULTING NN CONFUSION MATRIX CONSIDERING LDA DIMENSIONALITY REDUCTION

Assigned Class	True Class			
	HLT	UNB	1/2 BRB	1 BRB
HLT	50	0	0	0
UNB	0	43	0	5
1/2 BRB	0	0	50	0
1 BRB	0	7	0	45

## VI. CONCLUSIONS

The proposed study shown the diagnosis capabilities of a statistical data fusion scheme dealing with different fault conditions in a kinematic chain. There are three important aspects in this study. First, the classical characteristic frequency analysis shows some limitations, that is, the stator current analysis exhibits viable differences in the corresponding components, while the vibration signal shows a complex frequency spectrum that makes difficult the faults identification. Second, the statistical time-domain features analysed exhibit significant fault identification capabilities, mainly, considering the vibration signal as a source of information. Third, the fusion of both signals, stator current and vibration signal represents the best approach for the diagnosis of the considered conditions.

In regard with the dimensionality reduction methods, the PCA seeks for a global data representation, thus, considering the unsupervised operation, a set of non-connected data clusters have a negative impact over the resulting representation. In this regard, as expected, the LDA shows better discriminative capabilities during the visualization of the results.

Finally, it should be notice that, dealing with industrial applicability requirements, a significant information arises from the studied health assessment scheme. The identification of deviations over the nominal condition through the diagnosis probability analysis, which represents an interesting capability since unexpected faults not initially characterized may appear during the useful life of the electromechanical system.

## REFERENCES

- [1] R. H. C. Palácios, I. N. da Silva, A. Goedel, W. F. Godoy and T. D. Lopes, "Diagnosis of Stator Faults Severity in Induction Motors Using Two Intelligent Approaches," in *IEEE Transactions on Industrial Informatics*, vol. 13, no. 4, pp. 1681-1691, Aug. 2017.
- [2] H. Hassani, J. Zarei, M. M. Arefi and R. Razavi-Far, "zSlices-Based General Type-2 Fuzzy Fusion of Support Vector Machines With Application to Bearing Fault Detection," in *IEEE Transactions on Industrial Electronics*, vol. 64, no. 9, pp. 7210-7217, Sept. 2017.
- [3] M. Seera and C. P. Lim, "Online Motor Fault Detection and Diagnosis Using a Hybrid FMM-CART Model," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 4, pp. 806-812, April 2014.
- [4] W. Sun, R. Zhao, R. Yan, S. Shao and X. Chen, "Convolutional Discriminative Feature Learning for Induction Motor Fault Diagnosis," in *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3, pp. 1350-1359, June 2017.
- [5] M. Y. Kaikaa, M. Hadjani and A. Khezzar, "Effects of the simultaneous presence of static eccentricity and broken rotor bars on the stator current of induction machine," in *IEEE Transactions on Industrial Electronics*, vol. 61, no. 5, pp. 2452-2463, May 2014.
- [6] E. Hashish, K. Miller, W. Finley and S. Kreitzer, "Vibration Diagnostic Challenges: Case Studies in Electric Motor Applications," in *IEEE Industry Applications Magazine*, vol. 23, no. 4, pp. 22-34, Aug. 2017.
- [7] H. Kia, H. Henao and G. A. Capolino, "Fault Index Statistical Study for Gear Fault Detection Using Stator Current Space Vector Analysis," in *IEEE Transactions on Industry Applications*, vol. 52, no. 6, pp. 4781-4788, Nov.-Dec. 2016.
- [8] B. R. Nayana and P. Geethanjali, "Analysis of Statistical Time-Domain Features Effectiveness in Identification of Bearing Faults From Vibration Signal," in *IEEE Sensors Journal*, vol. 17, no. 17, pp. 5618-5625, Sept. 1, 2017.
- [9] J. J. Saucedo-Dorantes, M. Delgado-Prieto, R. A. Osornio-Rios and R. de Jesus Romero-Troncoso, "Multifault Diagnosis Method Applied to an Electric Machine Based on High-Dimensional Feature Reduction," in *IEEE Transactions on Industry Applications*, vol. 53, no. 3, pp. 3086-3097, May-June 2017.
- [10] M. Van, H. J. Kang, "Wavelet kernel local fisher discriminant analysis with particle swarm optimization algorithm for bearing defect classification," in *IEEE Trans. Instrum. Meas.*, vol. 64, no. 12, pp. 3358-3600, Dec. 2015.
- [11] O. Duque-Perez, C. Del Pozo-Gallego, D. M. Sotelo and W. F. Godoy, "Bearing fault diagnosis based on Lasso regularization method," in *Proc. IEEE Int. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Tinos, 2017, pp. 331-337.
- [12] Q. He, X. Ding, and Y. Pan, "Machine Fault Classification Based on Local Discriminant Bases and Locality Preserving Projections," *Mathematical Problems in Engineering*, vol. 2014, pp. 1-12, 2014.
- [13] T. Ince, S. Kiranyaz, L. Eren, M. Askar and M. Gabbouj, "Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks," in *IEEE Trans. on Ind. Electronics*, vol. 63, no. 11, pp. 7067-7075, Nov. 2016.
- [14] Y. Peng, W. Qiao, L. Qu and J. Wang, "Gearbox fault diagnosis using vibration and current information fusion," in *IEEE Energy Conversion Congress and Exposition (ECCE)*, Milwaukee, WI, pp. 1-6, Sept. 2016.
- [15] F. Cheng, Y. Peng, L. Qu and W. Qiao, "Current-Based Fault Detection and Identification for Wind Turbine Drivetrain Gearboxes," in *IEEE Transactions on Industry Applications*, vol. 53, no. 2, pp. 878-887, March-April 2017.
- [16] A. Giantomassi, F. Ferracuti, S. Iarlori, G. Ippoliti and S. Longhi, "Electric Motor Fault Detection and Diagnosis by Kernel Density Estimation and Kullback-Leibler Divergence Based on Stator Current Measurements," in *IEEE Transactions on Industrial Electronics*, vol. 62, no. 3, pp. 1770-1780, March 2015.
- [17] X. Jin, M. Zhao, T. W. S. Chow and M. Pecht, "Motor Bearing Fault Diagnosis Using Trace Ratio Linear Discriminant Analysis," in *IEEE Trans. on Ind. Electronics*, vol. 61, no. 5, pp. 2441-2451, May 2014.
- [18] A. Bellini, F. Filippetti, C. Tassoni and G. A. Capolino, "Advances in Diagnostic Techniques for Induction Machines," in *IEEE Transactions on Industrial Electronics*, vol. 55, no. 12, pp. 4109-4126, Dec. 2008.
- [19] Ž. Kanović, D. Matić, Z. Jeličić, M. Rapaić, B. Jakovljević and M. Kapetina, "Induction motor broken rotor bar detection using vibration analysis — A case study," in *Proc. IEEE Int. Symp. on Diag. for Elec. Mach., Power Electron. and Drives*, pp. 64-68, Valencia, 2013.
- [20] M. P. Norton, D. G. Karczub, M. P. Norton and D. G. Karczub. *Fundamentals of Noise and Vibration Analysis for Engineers*. 2nd ed. Cambridge: Cambridge University Press, 2003.