



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Doctorado en Mecatrónica

**Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos**

Tesis

Que como parte de los requisitos para obtener el grado de:

**Doctor en Mecatrónica**

**Presenta:**

Juan José Saucedo Dorantes

**Asesores:**

Dr. René de Jesús Romero Troncoso

San Juan del Río, Querétaro, Diciembre de 2017.



Universidad Autónoma de Querétaro  
 Facultad de Ingeniería  
 Doctorado en Mecatrónica

**Metodologías para mejorar la confiabilidad del diagnóstico de fallas en cadenas cinemáticas basado en algoritmos inteligentes y fusión de datos**  
 Tesis

Que como parte de los requisitos para obtener el grado de:

**Doctor en Mecatrónica**

Presenta:

**Juan José Saucedo Dorantes**

Dirigido por:

**Dr. René de Jesús Romero Troncoso**

**Dr. René de Jesús Romero Troncoso**

Presidente

**Dr. Roque Alfredo Osornio Rios**

Secretario

**Dr. Miguel Delgado Prieto**

Vocal

**Dr. Arturo Yosimar Jaen Cuellar**

Suplente

**Dr. J. Jesús de Santiago Pérez**

Suplente

*[Handwritten signature]*  
 Firma  
*[Handwritten signature]*  
 Firma  
*[Handwritten signature]*  
 Firma  
*[Handwritten signature]*  
 Firma  
*[Handwritten signature]*  
 Firma

*[Handwritten signature]*

**Dr. Aurelio Domínguez Gonzales**  
 Director de la facultad

*[Handwritten signature]*

**Dra. Ma. Guadalupe Flavia Loarca Piña**  
 Directora de investigación y posgrado

## RESUMEN

En las últimas décadas, la mayoría de las aplicaciones industriales han sufrido varios cambios con el objetivo de mejorar su efectividad y garantizar un alto rendimiento en diferentes procesos; de hecho, la competitividad industrial es el principal factor que ha empujado a la industria a realizar estos cambios. En este sentido, maquinaria de alta eficiencia se ha utilizado en la aplicación de la industria moderna para cumplir con los requisitos de competitividad demandados; por lo tanto, desde una perspectiva industrial, la competitividad se puede medir en términos de qué tan eficiente, preciso y robusto es un proceso.

De este modo, debido a que las aplicaciones de la industria moderna están involucradas con maquinaria especializada y sofisticada, la aparición repentina de fallas puede ser un problema crítico que puede llevar a afectar la eficiencia de los procesos de producción; además de eso, se generan pérdidas económicas debido a la aparición de fallas inesperadas, por lo tanto, se deben desarrollar esquemas de monitoreo de condiciones para evitar estos problemas y asegurar la disponibilidad de la maquinaria. Aún más, si el tipo maquinaria especializada está basado en una cadena cinemática compuesta por elementos mecánicos y eléctricos, la aparición de fallas será inherente a su funcionamiento.

En este sentido, esta tesis propone una metodología de diagnóstico basada en técnicas de fusión de datos y algoritmos inteligentes para diagnosticar, identificar y clasificar la aparición de múltiples fallas en una cadena cinemática. De hecho, la contribución de este trabajo de investigación es la propuesta y validación de que el uso y la aplicación adecuada de técnicas de fusión de datos y algoritmos inteligentes en los esquemas de monitoreo de condiciones pueden conducir a aumentar la confiabilidad del diagnóstico de fallas. La metodología propuesta se valida bajo un conjunto completo de conjuntos de datos experimentales, donde se evalúan cuatro condiciones diferentes en una caja de engranajes y en un motor de inducción se evaluaron seis condiciones diferentes. Los resultados obtenidos representan un diagnóstico de falla de alto rendimiento para la evaluación de una cadena cinemática bajo diferentes condiciones de operación.

**(Palabras clave:** monitoreo de condición, cadena cinemática, motor de inducción, caja de engranes, cálculo de indicadores, identificación de fallas)

## SUMMARY

In the last decades, most of the industrial applications have been subjected to several changes aiming to improve its effectiveness and to ensure a high-performance in different processes; in fact, the industrial competitiveness is the main factor that has pushed the industry to make these changes. In this sense, high-efficiency machinery has been used in application of the modern industry to fulfill the demanded competitiveness requirements; thus, from an industrial perspective, competitiveness can be measured in terms of how efficient, accurate and robust is a process.

Thereby, due to applications of modern industry are involved with specialized and sophisticated machinery, the sudden appearance of faults can be a critical problem that may lead to affect the efficiency of production processes; besides that, economical losses are generated due to unexpected breakdowns, hence, condition monitoring schemes have to be developed to avoid these problems and to ensure the machinery availability. Even more, if the specialized machinery consists of kinematic chain composed by mechanical and electrical elements, the occurrence of faults is inherent to its operation.

In this regard, this thesis proposes a diagnosis methodology based on data fusion techniques and intelligent algorithms to diagnose, identify and classify the appearance of multiple faults in a kinematic chain. Indeed, the contribution of this research work is the proposal and validation that the use and proper application of data fusion techniques and intelligent algorithms in condition monitoring schemes may lead to increase the reliability of fault diagnosis. The proposed methodology is validated under a complete set of experimental data set, where four different conditions are evaluated in a gearbox and in an induction motor are tested six different conditions. The obtained results represent a high-performance fault diagnosis for the assessment of a kinematic chain under different operating conditions.

**(Key words:** condition monitoring, kinematic chain, induction motor, gearbox, feature calculation, fault identification)

Especialmente a mis padres, quienes siempre han dado lo mejor de sí mismos y quienes se han esforzado al máximo brindándome su apoyo incondicional.

## **AGRADECIMIENTOS**

Primero que nada, quiero agradecer a mi familia porque siempre han estado conmigo en todo momento, a ellos les debo muchos logros que he obtenido y este es otro más que les compartiré. Me siento muy orgulloso de ellos por las grandes personas que son, han sido un buen ejemplo y siempre nos han guiado por el camino correcto a mí y a mis hermanos; y porque además nunca nos han dejado rendirnos ante cualquier situación y siempre nos han dado alientos de seguir adelante en las situaciones más difíciles.

También quiero agradecer a mis asesores de tesis, primero al Dr. René y al Dr. Roque, quienes desde mis estudios de maestría me brindaron la oportunidad de hacer equipo de trabajo con ellos; y aunque me mostré temeroso al iniciar este proyecto, ellos nunca perdieron la esperanza en que algo bueno se iba a dar de esto; y así fue, ahora gracias a ellos y al trabajo en equipo que realizamos he descubierto nuevas fronteras que me apasionan, no tengo como agradecerles que hayan confiado en mi trabajo. Asimismo, quiero agradecerle muy en especial a Miguel, una gran persona que sin conocerme tomó el riesgo y también me integró en su equipo de trabajo; nunca imagine poder viajar al extranjero para fortalecer mis conocimientos, y haber realizado una estancia de investigación bajo su tutela fue una de las más grandes experiencias que he tenido en mi formación, me dio mucho gusto haber trabajado con él y espero poder seguir haciéndolo en la medida que se pueda.

También agradezco a mis compañeros de maestría y doctorado que hicieron ameno el tiempo que pase en las intenciones de la Universidad durante estos últimos tres años y medio.

Además, agradezco mucho a mi novia Aide por estar presente tomando mi mano y brindarme su cariño y comprensión en este último año, este logro que obtengo también le pertenece.

Por último, agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por haberme ofrecido una beca de manutención durante la realización de este proyecto de investigación.

## ÍNDICE GENERAL

AGRADECIMIENTOS.....	iv
ÍNDICE GENERAL.....	v
ÍNDICE DE FIGURAS.....	viii
ÍNDICE DE TABLAS.....	x
1. Introducción.....	1
1.1 Antecedentes.....	2
1.1.1 Importancia del monitoreo y diagnóstico de fallos en procesos industriales.....	2
1.1.2 Diagnóstico de fallas en cadenas cinemáticas mediante vibraciones mecánicas.....	5
1.1.3 Diagnóstico de fallas en cadenas cinemáticas usando otros parámetros de medición.....	10
1.1.4 Técnicas basadas en la fusión de datos y algoritmos para detección de fallas en cadenas cinemáticas.....	12
1.1.5 Efectos que generan las fallas en cadenas cinemáticas y la confiabilidad en el monitoreo y diagnóstico.....	15
1.2 Objetivos e hipótesis.....	16
1.2.1 Objetivos.....	16
1.2.2 Hipótesis.....	17
1.3 Justificación.....	17
1.4 Planteamiento general.....	19
2. Fundamentación teórica.....	21
2.1 Fallas en cadenas cinemáticas.....	21
2.1.1 Rodamientos dañados.....	21
2.1.2 Fallas en rotores por barras rotas.....	23
2.1.3 Fallas de excentricidad y desalineamiento.....	24
2.1.4 Fallas en engranes.....	24
2.2 Calculo de indicadores.....	26
2.2.1 Técnicas de análisis de señales basadas en el dominio del tiempo.....	27
2.2.2 Técnicas de análisis de señales basadas en el dominio de frecuencia.....	27
2.2.3 Técnicas de análisis de señales basadas en el dominio de tiempo-frecuencia.....	29
2.2.4 Técnicas de análisis de señales basadas en descomposiciones.....	30

2.3	Reducción de indicadores.....	31
2.3.1	Selección de indicadores .....	32
2.3.2	Extracción de indicadores.....	33
2.4	Algoritmos inteligentes de clasificación y optimización.....	39
2.4.1	Redes neuronales .....	39
2.4.2	Sistemas de inferencia difusa .....	41
2.4.3	Algoritmos genéticos.....	42
2.5	Cálculo de indicadores de confiabilidad.....	42
3.	Metodologías de diagnóstico .....	45
3.1	Instrumentación de la cadena cinemática .....	46
3.1.1	Fallas evaluadas en el motor de inducción .....	48
3.1.2	Fallas evaluadas en la caja de engranes.....	50
3.2	Análisis de los efectos generados por la combinación de fallas de la caja de engranes y el motor de inducción .....	51
3.3	Identificación y clasificación de las diferentes severidades de desgaste uniforme en engranes.....	53
3.4	Detección y clasificación de múltiples fallas en el motor de inducción.....	56
3.4.1	Descomposición de señales de vibración y cálculo de indicadores.....	57
3.4.2	Reducción de dimensionalidad de indicadores en múltiples etapas .....	58
3.4.3	Clasificación .....	60
3.5	Evaluación de la confiabilidad del diagnóstico de fallas en la cadena cinemática .....	61
4.	Resultados y discusiones.....	63
4.1	Análisis de los efectos generados por la combinación de fallas de la caja de engranes y el motor de inducción .....	63
4.2	Identificación y clasificación de las diferentes severidades de desgaste uniforme en engranes.....	73
4.3	Detección y clasificación de múltiples fallas en el motor de inducción.....	79
4.4	Evaluación de la confiabilidad del diagnóstico de fallas en la cadena cinemática .....	88
5.	Conclusiones .....	90



6. REFERENCIAS.....	92
7. APÉNDICE.....	97
Artículos publicados en revista Indizada JCR (Journal Citation Report).....	97
Artículos de congreso .....	97

## ÍNDICE DE FIGURAS

Figura 1. Fresadora CNC basada en una cadena cinemática.....	4
Figura 2. Instalación típica de acelerómetros para la medición de vibraciones en una cadena cinemática (Henao et al., 2011).....	7
Figura 3. Fallas clásicas estudiadas. (a) Pista interna de rodamiento dañada (Bediaga et al., 2013). (b) Fractura en diente de engrane (Ebrahimi et al., 2013).....	9
Figura 4. Cadena cinemática formada por elementos mecánicos y eléctricos. ....	14
Figura 5. Planteamiento general del proyecto para desarrollar una metodología de monitoreo y diagnóstico de múltiples fallas en una cadena cinemática. ....	19
Figura 6. Rodamiento de bolas y sus partes. ....	22
Figura 7. Espectro de vibraciones de una caja de engranes en estado: (a) sano y (b) desgaste de engranes. ....	26
Figura 8. Proceso de extracción de indicadores mediante la PCA. (a) Conjunto inicial de indicadores en un espacio 3D. (b) Ubicación de las componentes principales. (c) Representación del conjunto de indicadores extraídos en un espacio 2D. ....	35
Figura 9. Proceso de extracción de indicadores mediante SOM: (a) datos de entrada e inicialización aleatoria, (b) entrenamiento resultante, y (c) evaluación de un nuevo punto. ....	39
Figura 10. Composición básica de una NN. ....	40
Figura 11. Diagrama general de la metodología desarrollada para la cinemática y su instrumentación ....	46
Figura 12. Banco de pruebas experimentales basado en una cadena cinemática.....	48
Figura 13. Conjunto de fallas evaluadas en el motor de inducción. (a) Rodamiento dañado. (b) ½ barra rota. (c) 1 barra rota. (d) Desbalance. (e) Desalineamiento.....	50
Figura 14. Conjunto de engranes maquinados: (a) Sano, (b) 25 %, (c) 50 % y (d) 75 % de desgaste uniforme, respectivamente. ....	51
Figura 15. Diagrama bloques para efectuar el análisis de los efectos generados por combinar fallas de la caja de engranes y el motor de inducción. ....	53
Figura 16. Diagrama bloques empleado para el monitoreo y diagnóstico del desgaste de engranes en diferentes condiciones de operación.....	56
Figura 17. Diagrama bloques empleado durante el monitoreo y diagnóstico de múltiples fallas en el motor de inducción.....	61
Figura 18. Espectro de vibraciones para la condición sana de la cadena cinemática y cuando el motor de inducción se operó a 15Hz. ....	65
Figura 19. Espectro de vibraciones para la condición de 50% de desgaste uniforme de la caja de engranes, motor de inducción en estado sano y frecuencia de operación de 50Hz..	65
Figura 20. Espectro de vibraciones para cuando el motor de inducción se operó a 5Hz para las condiciones de: (a) cadena cinemática sana, (b) rodamiento dañado del motor de	

inducción, (c) 75% de desgaste uniforme en la caja de engranes, y (d) combinación de rodamiento dañado con desgaste uniforme de 75%. .....	68
Figura 21. Espectro de densidades de potencia de señales de corriente para cuando el motor de inducción se operó a 50 Hz para las condiciones de: (a) diferentes severidades de desgaste en la caja de engranes, (b) combinación de falla de desgaste uniforme con rodamiento dañado. ....	72
Figura 22. Proyecciones de los conjuntos de indicadores extraídas mediante la LDA para cuando el motor opero a: (a) 5Hz, (b) 15Hz y (c) 50Hz.....	77
Figura 23. Rendimiento del GA durante la optimización del número de IMF's para representar cada falla considerada, evolución y porcentaje máximo de la varianza acumulada obtenida: (a) rodamiento dañado, (b) ½ barra rota, (c) 1 barra rota, d) desbalance, y e) desalineamiento.....	81
Figura 24. Diagrama de dispersión del conjunto optimizado de IMF's (IMF2 e IMF2) para la condición de desalineación usando dos componentes principales en la PCA. ....	82
Figura 25 Diagrama de dispersión de un conjunto aleatorio de IMF's (IMF8, IMF9 y IMF10) para la condición de desalineación usando dos componentes principales en la PCA.	82
Figura 26. Proyección del conjunto extraído de características resultante de la aplicación de la estrategia de reducción de indicadores híbrida propuesta. ....	85
Figura 27. Proyección de las regiones de decisión resultantes del algoritmo de clasificación basado en NN para el conjunto de datos utilizados durante: (a) el entrenamiento de la NN y (b) la prueba de la NN. ....	87

## ÍNDICE DE TABLAS

Tabla 2.1 Indicadores estadísticos utilizados en el análisis de señales de dominio del tiempo. ....	28
Tabla 4.1 Frecuencias características de falla calculadas a partir de la velocidad de rotación del motor de inducción. ....	64
Tabla 4.2 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 5 Hz. ....	69
Tabla 4.3 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 5 Hz. ....	69
Tabla 4.4 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 15 Hz. ....	69
Tabla 4.5 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 15 Hz. ....	69
Tabla 4.6 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 50 Hz. ....	70
Tabla 4.7 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 50 Hz. ....	70
Tabla 4.8 Componentes de frecuencia a analizar en los espectros de corriente. ....	72
Tabla 4.9 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 50 Hz. ....	73
Tabla 4.10 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 50 Hz. ....	73
Tabla 4.11 Detalle de los subconjuntos de indicadores seleccionados por considerar la combinación de tres indicadores para el cálculo del coeficiente de Fisher. ....	75
Tabla 4.12 Rendimiento de la clasificación obtenida durante el entrenamiento y prueba del sistema de inferencia Fuzzy bajo las condiciones consideradas a diferentes frecuencias de operación. ....	78
Tabla 4.13 Detalle del conjunto indicadores estadísticos obtenidos de las IMF's optimizadas al considerar dos componentes principales en el proceso de optimización. ....	80
Tabla 4.14 Detalle de los subconjuntos de indicadores seleccionados para las diferentes condiciones. ....	84
Tabla 4.15 Detalle de la matriz de transformación obtenida por la LDA para generar la proyección de los indicadores seleccionados en un espacio bidimensional. ....	85
Tabla 4.16 Matriz de confusión generada de la evaluación de las condiciones consideradas durante el proceso de entrenamiento del clasificador. ....	88
Tabla 4.17 Matriz de confusión generada de la evaluación de las condiciones consideradas durante el proceso de prueba del clasificador. ....	88

Tabla 4.18 Valores del coeficiente de Alfa de Cronbach obtenidos de los resultados de diagnóstico y clasificación de fallas en el motor de inducción. .... 89

# Capítulo I

## 1. Introducción

En las últimas décadas, la gran mayoría de las aplicaciones industriales han sido sometidas a una serie de cambios y transformaciones con el objetivo de mejorar la efectividad y asegurar el alto desempeño en sus diferentes procesos. De hecho, la competitividad industrial es uno de los factores más importantes que ha impulsado a la industria a realizar estos cambios y transformaciones; y esto no habría sido posible de realizar sin los avances que ha presentado la ingeniería. En este sentido, la maquinaria de alta eficiencia está siendo empleada en aplicaciones de la industria moderna para cumplir con los requerimientos de competitividad demandados. Así, desde una perspectiva industrial, la competitividad puede estar descrita en términos de que tan eficientes, precisos y robustos sean sus procesos; además de que uno de los principales objetivos de la industria es asegurar la condición de trabajo de la maquinaria para evitar las interrupciones costosas e inesperadas.

Por lo tanto, debido a que aplicaciones de la industria moderna están involucradas con el uso de maquinaria eficiente y sofisticada, la aparición repentina de interrupciones representa un problema crítico que puede conducir a la disminución de la efectividad de los procesos de producción. Para mantener la productividad a niveles competitivos se debe de asegurar la condición de trabajo de la maquinaria, esta es la razón por la cual los nuevos desafíos tecnológicos, innovadores y de investigación están enfocados en dar solución a problemas de maquinaria relacionados con condiciones de trabajo inapropiadas; de hecho, para el sector industria ha resultado interesante la inversión en investigación que tiene como objetivo crear nuevas estrategias de mantenimiento que minimicen la aparición de fallos inesperados y que al mismo tiempo maximicen la disponibilidad de la maquinaria.

Además, hoy en día ya existe una gran variedad de maquinaria que puede ser empleada para realizar determinadas tareas específicas en un proceso industrial; de este modo, la configuración de esta maquinaria e incluso el uso de múltiples máquinas dependerá de la aplicación y el proceso a realizar. En general, toda aquella maquinaria empleada en aplicaciones industriales está compuesta tanto por elementos eléctricos como mecánicos, de estos elementos destacan principalmente los motores de inducción, las cajas reductoras de

engranajes, los acoples mecánicos, las flechas de transmisión, entre otros. La interconexión de estos elementos compone la cadena cinemática de funcionamiento de la máquina, con esto se entiende que para asegurar el correcto funcionamiento y disponibilidad de la maquinaria se deben de mantener en buen estado aquellos elementos de la cadena cinemática.

En esta tesis se describe el desarrollo de una metodología para el diagnóstico de fallas en cadenas cinemáticas basadas en algoritmos inteligentes y fusión de datos. El trabajo está dividido en cinco capítulos, en los cuales está la descripción completa de este proyecto de investigación. En el presente capítulo se presenta el panorama general y tópicos de interés de este trabajo, también se incluyen los antecedentes, hipótesis, objetivos, justificación y el planteamiento general, que dieron origen a este proyecto de investigación. En el capítulo dos se presenta la revisión de la literatura referente a esquemas de monitoreo y diagnóstico de fallos en cadenas cinemáticas, en este capítulo se incluyó la fundamentación teórica que sustentan el desarrollo y ayudan en la comprensión de este trabajo. En el capítulo tres se presenta la metodología que en este trabajo de investigación se siguió para realizar acciones de condición de monitoreo y diagnóstico de fallas en una cadena cinemática. Los resultados y conclusiones quedaron descritos en el capítulo cuatro y cinco respectivamente, en la sección de conclusiones también se incluyeron prospectivas para este trabajo. Finalmente se puede encontrar una sección dedicada para las referencias y un apéndice donde se han incluido los artículos publicados en revistas indexadas JCR (Journal Citation Report).

## **1.1 Antecedentes**

### **1.1.1 Importancia del monitoreo y diagnóstico de fallos en procesos industriales**

La confiabilidad al realizar acciones de condición de monitoreo y diagnóstico de fallas en procesos industriales está obteniendo cada vez más importancia, esto por la necesidad que existe de mantener e incrementar la disponibilidad de las máquinas. El mal funcionamiento de maquinaria en diferentes aplicaciones industriales comúnmente tiende a reducir la productividad e incrementar los costos de mantenimiento; por esta razón, mejorar la confiabilidad en acciones de condición de monitoreo y diagnóstico es uno de los objetivos que está siendo abordado en el reconocimiento de fallas incipientes. Debido a que la detección temprana de cualquier tipo de falla es importante para prevenir el mal funcionamiento de maquinaria en aplicaciones industriales, las acciones de condición de

monitoreo y diagnóstico son parte importante en la implementación de procesos y planes de mantenimiento en la industria. Tan significativo ha sido realizar el monitoreo y diagnóstico de fallos en algunas máquinas de aplicación específica que ya científicos se han mostrado preocupados y han realizado algunas revisiones destacando las tendencias en el diagnóstico de fallos y técnicas que están siendo utilizadas para su diagnóstico (Henao et al., 2014).

Poner en práctica acciones de condición de monitoreo y diagnóstico ha tenido un gran impacto en sector industrial, esto ha sido tan importante que en los últimos años se ha generado un incremento en la cantidad de investigaciones en el campo científico. En estas investigaciones se han planteado como objetivo el determinar indicadores importantes que ayuden en el diagnóstico de procesos industriales, ejemplo de esto es el trabajo de Tobon et al. (2012) quienes utilizando una red de aprendizaje con un conjunto de patrones adquiridos de señales de vibración y acústica obtuvieron un modelo del comportamiento del desgaste en cortadores de una máquina CNC; posteriormente, en base a sus modelos obtenidos realizan una evaluación y dan el diagnóstico del estado de la herramienta. Otro trabajo es el de Valtierra-Rodríguez et al. (2013 a) quienes propusieron una metodología basada en redes neuronales (Neural Network-NN) para la evaluación de los índices de calidad de la energía en sistemas trifásicos, en el análisis que propusieron se evalúan aquellos índices calculados de los estados transitorios de señales de corriente y mediante la transformada corta de Fourier (Short Time Fourier Transform-STFT) muestran la evolución de las distorsiones armónicas; básicamente este sistema desarrollado lo emplean en el monitoreo y diagnóstico de la calidad de la energía.

La industria automotriz también es importante, a este respecto, Shatnawi y Al-khassaweneh (2014) propusieron un estudio para realizar la clasificación de fallas en un motor de combustión interna mediante la adquisición de señales de sonido, su estudio está basado en la descomposición de señales con Wavelets (Wavelet Packet Decomposition-WPD) y una NN; por otra parte, Anami y Pagi (2013) desarrollaron una metodología para la localización de múltiples fallas en una motocicleta, ellos también realizaron una descomposición de sus señales de sonido obtenidas utilizando WPD, y con una NN hacen el reconocimiento y obtienen la clasificación de las fallas estudiadas.

Actualmente la industria es uno de los sectores productivos de mayor importancia a nivel mundial, y gran parte de sus procesos se ven involucrados con el uso de maquinaria



especializada. Parte fundamental de este tipo de máquinas industriales son los sistemas mecánicos rotativos, este tipo de sistemas pueden estar sujetos a la aparición inesperada de fallas y debido a esto es necesario contar con métodos y sistemas de monitoreo que ayuden a determinar el estado sano de operación y que así mismo garanticen la vida útil del sistema. Debido al rápido desarrollo tecnológico-científico que en los últimos años se ha logrado debido a los avances de la ingeniería, las aplicaciones industriales han presentado una serie de cambios y transformaciones con la finalidad de optimizar sus procesos; en consecuencia, se ha recurrido a la utilización de maquinaria con estructuras complejas en donde es más difícil tratar de diagnosticar e identificar la presencia de fallos.

Un área importante de análisis en procesos industriales y sobre la cual se están aplicando acciones de condición de monitoreo y diagnóstico son las cadenas cinemáticas, se denomina cadena cinemática al conjunto de elementos unidos entre sí por medio de acoplamientos, el objeto de una cadena cinemática consiste en producir o transformar un movimiento determinado en otro del mismo o diferente tipo (Uicker et al., 2011). En este sentido, la mayoría de procesos y máquinas se ven involucrados con la utilización de cadenas cinemáticas, ejemplo de esto son las máquinas herramienta como las fresadoras y tornos que cuentan con un sistema electromecánico que generalmente está compuesto por motores, cajas de engranes, acoplamientos, entre otros. Así, estos elementos que forman la cadena cinemática de máquinas herramienta son empleados para ejecutar los movimientos requeridos durante el proceso de maquinado; en la Figura 1 se muestra una imagen de una máquina la cual cuenta con una cadena cinemática.



Figura 1. Fresadora CNC basada en una cadena cinemática.

En el mantenimiento existe indicadores cuantificables que han sido utilizado con un propósito específico, a través de estos indicadores se puede medir la gestión y dar una idea del comportamiento del proceso de mantenimiento en una empresa. Además, estos indicadores son parámetros numéricos que convenientemente utilizados pueden ofrecer una oportunidad de mejora continua en el desarrollo, aplicación de métodos y técnicas específicas para el mantenimiento. La magnitud de los indicadores normalmente se suele comparar con valores o niveles de referencia previamente establecidos, esto con el objetivo de realizar acciones correctivas, preventivas o predictivas según sea el caso. La confiabilidad, mantenibilidad y disponibilidad son prácticamente las únicas medidas técnicas y científicas, fundamentadas en cálculos matemáticos, estadísticos y probabilísticos, que tiene el mantenimiento para su análisis.

### **1.1.2 Diagnóstico de fallas en cadenas cinemáticas mediante vibraciones mecánicas**

Debido a que existe una gran necesidad por mantener en buenas condiciones de operación algún proceso industrial, se han realizado cada vez más investigaciones científicas, que han propuesto, desarrollado y estudiado métodos de condición de monitoreo y diagnóstico con el fin de detectar y pronosticar algún estado de falla en alguno de los componentes en una cadena cinemática. Anteriormente ya se habían estudiado una buena cantidad de fallas en cadenas cinemáticas; sin embargo, la mayoría de estos análisis han estudiado la aparición de fallas en componentes específicos. La aparición de fallas en cadenas cinemáticas puede ser de tipo eléctricas o mecánicas, ejemplo de fallas pueden ser aquellas generadas por barras rotas en motores de inducción, daños en rodamientos de ejes, desbalance y desalineamiento en poleas, flechas o acoplamientos mecánicos y fallas en sistemas de engranes de cajas reductoras (Tung et al. 2012, Lei et al. 2013).

La aparición de vibraciones en cadenas cinemáticas está relacionada con la aparición de fallos mecánicos y eléctricos, por lo que la utilización de esta magnitud física ha sido importante en acciones de condición monitoreo y diagnóstico de fallas. En este sentido, se han realizado investigaciones que han empleado diferentes técnicas y algoritmos basados en el análisis de vibraciones para la identificación de condiciones de falla; como Bediaga et al. (2013) quienes determinaron el daño en rodamientos mediante el análisis de señales de vibración, en su análisis emplearon técnicas de procesamiento como la transformada rápida de Fourier (Fast Fourier Transform-FFT), demodulación de amplitud y

la transformada Hilbert-Huang (Hilbert Huang Transform-HHT). Aunque en este trabajo solo estudiaron fallas sobre las pistas del rodamiento los resultados reportados fueron buenos debido a que realizaron el análisis espectral con las diferentes técnicas mencionadas; por lo tanto, es bien sabido que estas técnicas de procesamiento son buenas por permitir conocer las componentes espectrales de fallo de los rodamientos.

El desarrollo de plataformas y sistemas embebidos para realizar acciones de condición de monitoreo y diagnóstico también han tenido gran impacto, ejemplo de esto es el trabajo de Chen et al. (2012) quienes realizaron el monitoreo en una caja de engranes con un sistema embebido que instalaron dentro de la misma, en este trabajo diagnosticaron la presencia de fallas en los rodamientos mediante el análisis espectral basado en las señales de vibración adquiridas; aunque las mediciones que realizaron son precisas se tienen la desventaja de que no en todos los sistemas rotatorios es posible instalar sensores en su interior. Otros estudios han tratado de generalizar la aplicación de sus métodos para la detección de fallos y han abordado el análisis de diferentes fallos cuyo origen es el mismo; por ejemplo, Wang et al. (2011 b) propusieron un método de detección de fallas en rodamientos para máquinas rotatorias, su método de diagnóstico está basado en la correlación y filtrado de señales de vibración, y con la técnica de Wavelets obtienen los periodos de los transitorios generados por la falla en rodamientos; aunque estudian tres fallas diferentes en rodamientos cuando realizan la experimentación no hacen la combinación de ellas.

Tan importante ha sido realizar acciones de monitoreo y diagnóstico que ya algunas investigaciones han implementado algoritmos inteligentes en sus esquemas de monitoreo para facilitar la clasificación de algún tipo de fallo y generar un diagnóstico automático de los sistemas o procesos, como el trabajo de Kateris et al. (2013) quienes desarrollaron una arquitectura para el diagnóstico de fallas ocasionadas por rodamientos en una caja de engranes, en esta arquitectura está basada en el análisis de señales de vibración y a través de NN's hacen la clasificación de las fallas; a pesar de que la técnica que proponen es buena en su estudio solo abordan el análisis dos fallos diferentes en rodamientos (fallas sobre la pista interior y exterior). Otro trabajo es el de Zhang y Zhou (2013) quienes presentaron una metodología para realizar el diagnóstico de múltiples fallas ocasionadas por rodamientos, ellos utilizan señales de vibración adquiridas de pruebas experimentales, a estas señales las

procesaron usando la técnica de descomposición de modos empíricos (Empirical Mode Decomposition-EMD) y utilizaron el método de aprendizaje conocido como máquinas de soporte vectorial (Support Vector Machine-SVM) para determinar las diferentes condiciones de fallo de los rodamientos; en su estudio analizan tres fallas distintas (fallas sobre las balas, en la pista interior y exterior) pero su enfoque lo hacen sobre fallas simples en el mismo elemento y además nunca realizan la combinación de las fallas.

Una gran cantidad de trabajos utilizan señales de vibración para determinar la condición de alguno de los componentes de una cadena cinemática, la presencia de fallos en cualquiera de los componentes de una cadena cinemática modificará la amplitud de las oscilaciones vibratorias. Por lo tanto, el uso de señales de vibración es apropiado en esquemas de condición de monitoreo y diagnóstico de fallos debido a que la mayoría de sensores de vibración se instalan directamente sobre el elemento de estudio, con esto se puede decir que los esquemas de monitoreo y diagnóstico basado en el análisis de vibración son confiables. En la Figura 2 se muestra un ejemplo de instalación típica de un par de acelerómetros que se utilizaron para realizar la medición de vibraciones sobre la caja de engranes en una cadena cinemática.




Figura 2. Instalación típica de acelerómetros para la medición de vibraciones en una cadena cinemática (Henaó et al., 2011).

Así como se han realizado estudios sobre fallas en rodamientos también existen algunos trabajos que se enfocan en sistemas de engranes; por ejemplo, Lei et al. (2010) identificaron diferentes categorías de daño en engranes, ellos realizan un análisis en el tiempo, frecuencia y tiempo-frecuencia en señales de vibración adquiridas, emplean las técnicas de HHT, FFT, EMD y WPD para obtener los indicadores de fallo relacionados con el estado sano y de fallo de los engranes; finalmente, utilizan un algoritmo genético (Genetic

Algorithm-GA) para realizar la clasificación de fallas de diente roto y fractura gradual de 20% y 50% de la raíz del diente, y aunque con la metodología que proponen se obtienen buenos resultados el tipo de fractura que inducen sobre los engranes no es muy realista ya que no existen fundamentos suficientes que describan el desarrollo gradual de la fractura de dientes. Otro trabajo es el de Wang et al. (2011 a) quienes utilizaron un método de diagnóstico basado en indicadores de estado sano para un sistema de engranes, estos indicadores que determinan el error residual de señales de vibración los obtuvieron empleando la transformada Comblet; a pesar de que comparando las amplitudes que alcanzan estos indicadores pueden hacer la distinción entre engranes en estado sano y de fallo, el tipo de daño inducido en los engranes es demasiado severo por deteriorar gran parte de los dientes del engrane.

El campo de aplicación en el que se ven involucradas las cajas de engranes es muy amplio debido a la confiabilidad y robustez que ofrecen, un campo de aplicación importante es el de los sistemas de generación eólica en donde daños catastróficos podrían ser generados por el mal funcionamiento en sus sistemas de transmisión. En este sentido ya se han realizado algunos estudios de detección de fallas, tal es el caso de Zappalá et al. (2013) quienes presentaron un algoritmo para el monitoreo de condición y detección de fallas en engranes de una transmisión de un sistema eólico, y utilizando señales de vibración adquiridas realizan un análisis espectral sobre las amplitudes de la frecuencia de engranaje y sus respectivos armónicos; de esta forma el diagnóstico lo obtienen comparando el comportamiento que presentan las bandas laterales de la frecuencia de engranaje, esta técnica les permitió obtener buenos resultados; sin embargo, solo estudiaron las fallas de fractura parcial y total del diente así como la aparición temprana de desgaste. Una falla común y que siempre estará presente en sistemas rotatorios con engranes es el desgaste que inevitablemente es ocasionado por la fricción que existe entre dientes de engranes; a este respecto, Huh et al. (2012) presentaron una contribución para el diagnóstico de fallas en engranes en un sistema electromecánico, específicamente estudian el movimiento de servomotores y mediante un observador estiman el error cinemático ocasionado por desgaste inducido en uno de los engranes, su propuesta es buena pero no en todos los sistemas mecánicos rotatorios con engranes será posible cuantificar el movimiento de cada uno de los engranes para hacer la estimación del error cinemático.

En lo que corresponde a engranes también se han utilizado algoritmos inteligentes en esquemas de condición de monitoreo buscando generar la identificación y clasificación automática de fallas, como Ebrahimi et al. (2013) quienes desarrollaron un método inteligente para el diagnóstico de una caja de engranes de un tractor agrícola, y utilizando señales de vibraciones en conjunto con algoritmos genéticos y una red neuronal hacen el diagnóstico y clasificación de las fallas; aunque los resultados que reportan son buenos en su experimentación solo estudian fallas como el desgaste y la fractura de varios dientes en un engrane, además de que no son muy realista sus experimentaciones por tener a los engranes del banco de pruebas sin lubricación y este tipo de condiciones en las que se realizaron las pruebas no tienen parecido con alguna aplicación. En la Figura 3 se muestran ejemplos comunes de fallas en rodamientos y engranes que han sido objeto de estudio por algunas investigaciones realizadas en los últimos años.



Figura 3. Fallas clásicas estudiadas. (a) Pista interna de rodamiento dañada (Bediaga et al., 2013). (b) Fractura en diente de engrane (Ebrahimi et al., 2013).

Otros tipos de fallas en sistemas rotatorios diferentes a las de rodamientos y engranes también han sido abordadas, el desalineamiento y desbalance son fallas que también puede estar presente en sistemas rotatorios, Zhang et al. (2013 b) desarrollaron un trabajo donde propusieron un método de clasificación de desbalance y de igual forma empleando señales de vibración realizaron una descomposición con la WPD, y de cada una de las señales descompuestas calculan un espectro de frecuencias con la FFT para generar el conjunto de entrenamiento para una NN y realizar la clasificación del desbalance; en este trabajo reportan buenos resultados para la clasificación debido a que las pruebas experimentales las realizan en una bomba centrífuga y cuestiones como el desbalance en este tipo de sistemas son muy críticos por generar un incremento en la amplitud de vibraciones.

La falla del desbalance es tan crucial para cualquiera de los sistemas rotativos existentes, que algunos investigadores recomiendan realizar un estudio teórico completo y

profundo para determinar las vibraciones radiales que este tipo de falla pueda generar, y así determinar las componentes de frecuencias características del fallo (Salah et al., 2013). Otro trabajo con enfoque diferente es el de Seshadrinath (2014) quienes realizaron un análisis basado en señales de vibración para diagnosticar fallas entre espiras de un motor de inducción, a las señales de vibración las descomponen empleando WPD y con una red neuronal probabilística (Probabilistic Neural Network-PNN) determinan el estado del motor; a pesar de que la falla estudiada es de origen eléctrico, el uso y análisis de señales de vibración les permitió obtener buenos resultados ya que el daño está presente en el motor de inducción, y ante la presencia de carga las vibraciones mecánicas se incrementan. Esta es una buena aplicación del diagnóstico del estado de maquinaria donde se aplican análisis basados en señales de vibración los cuales ofrecen confiabilidad en el diagnóstico e identificación de fallas.

### **1.1.3 Diagnóstico de fallas en cadenas cinemáticas usando otros parámetros de medición**

Así como las vibraciones son utilizadas para realizar el monitoreo, diagnóstico y clasificación de fallas, también pueden emplearse otro tipos de señales como las de corriente de estator o de emisión acústica; en este sentido, Henríquez et al. (2014) hicieron una revisión enfocada al monitoreo y diagnóstico de fallas en los que utilizaron señales como las vibraciones y de emisión acústica, y encontraron que las publicaciones que basan su análisis en señales de vibración son mayores que las abordadas con sonido, también reportan que en vibraciones un poco más del 60% de publicaciones las dedican al estudio de fallas ocasionadas por rodamientos y engranes, y para señales de sonido cerca del 25% de trabajos se enfocan en las fallas de estos mismos componentes. Con esto se concluye que la mayoría de estrategias de monitoreo y diagnóstico de fallas han basado sus análisis en vibraciones, mientras que el monitoreo basado en señales acústicas u de otro tipo han sido empleados, pero no al mismo grado que las vibraciones.

Respecto a esto ya algunos trabajos en los que se han empleado señales acústicas, tal como Li y He (2012) quienes propusieron una metodología para el monitoreo y detección de fallas en una caja de engranes, de su experimentación con engranes sanos y engranes con fractura en la raíz del diente adquieren muestras de señales acústicas, y con un procesamiento de señales basado en EMD determinan el estado en el cual se encuentra el sistema; por el tipo

de falla que inducen es indiscutible que el ruido que genere el engrane dañado se incrementará inclusive hasta se presenta una demodulación en sus señales capturadas. Por otra parte, Li et al. (2012) utilizaron una metodología basada en Wavelets para determinar la localización de una falla en una caja de engranes, y para determinar la ubicación del engrane dañado implementaron una instrumentación con varios sensores de emisión acústica; su propuesta de detección de fallas es buena solo que depende de la instrumentación de varios sensores y además de que no determina el tipo de falla si no solo la ubicación. Otro ejemplo de aplicación diferente es el de Amarnath y Krishna (2012) quienes estudiaron el comportamiento de fallas generadas por rodamientos y engranes en un sistema mecánico, el diagnóstico del sistema lo obtienen mediante el procesamiento de señales acústicas utilizando EMD, y con valores estimados del RMS, Kurtosis y Skewness determinan la severidad de la falla; esta propuesta de análisis es buena solo que en su experimentación nunca hacen la combinación de fallas de ambos elementos.

Los análisis basados en otro tipo de señales también pueden ser empleado en acciones de condición de monitoreo y diagnóstico, y ya existen investigaciones realizadas como la de Soualhi et al. (2013) quienes basados en valores de indicadores estadísticos de señales de corriente de un motor de inducción detectan fallas de barras rotas y rodamientos, y mediante el agrupamiento de datos y el uso de inteligencia artificial (Artificial Intelligence-AI) obtienen una clasificación precisa de los fallos, los resultados que obtienen son precisos por dañar directamente más de dos barras en el rotor y afectar los consumos de corriente del motor de inducción. Otro trabajo es el de Henao et al. (2011) quienes desarrollaron una técnica no invasiva para el monitoreo y diagnóstico de un sistema de tracción de tren, y usando señales de corriente y voltaje del motor estiman el torque electromagnético y en base a las variaciones que presenta ofrecen el diagnóstico del sistema; el tipo de falla que indujeron afecto severamente los dientes de uno de los engranes provocando una distorsión armónica sobre las señales empleadas, y esto ocasionó que el torque electromagnético estimado presentara variaciones considerables.

En la mayoría de las estrategias de monitoreo de condición y diagnóstico de fallos se han asociado los tipos fallas con una variable física; por ejemplo, las fallas de origen mecánico se asocian con las vibraciones y las fallas de origen eléctrico con las corrientes de consumo. Sin embargo, también podrían analizar fallos mecánicos con variables eléctricas y



viceversa, tal es el caso de Bogiatzidis et al. (2013) quienes analizaron la aparición de vibraciones ocasionadas por el juego entre dientes de engranes, en su análisis utilizan señales de corriente del motor para obtener el torque electromagnético, y usando la FFT hacen un análisis espectral en la frecuencia de engranaje para determinar cuándo es que existe un juego excesivo entre dientes de engrane, su propuesta y análisis es buena pero los casos de estudio los realiza para engranes con demasiado juego e incluso más de dos dientes fracturados. En este sentido también Delgado et al. (2011) propusieron una metodología basada en la medición de diferentes magnitudes físicas como corriente, voltaje y vibraciones para diagnosticar el estado de un sistema electromecánico, y mediante la fusión de indicadores de fallas en conjunto la implementación de NN y GA obtienen la clasificación de las fallas; y aunque solo estudia fallas como la excentricidad y corto circuito su técnica propuesta es buena ya que incrementa la confiabilidad en el diagnóstico por haber usado diferentes magnitudes físicas.

Otro tipo de estudio para fallas en cadenas cinemáticas que actualmente se ha estado abordando es el que se realiza mediante el análisis de termografía, tal es el caso de Garcia-Ramirez et al. (2014) quienes propusieron y desarrollaron una metodología basada en un análisis termográfico para la determinación de fallas como las de rodamientos, desbalance y desalineamiento; esta metodología basada en termografía además de presentar buenos resultados tiene la ventaja de ser una técnica no invasiva y ofrece un amplio rango de análisis, además de que en este trabajo se introducen al estudio de las repercusiones que una falla específica ocasiona sobre el resto de la cadena cinemática.

#### **1.1.4 Técnicas basadas en la fusión de datos y algoritmos para detección de fallas en cadenas cinemáticas**

Ya existen algunos estudios que de alguna forma han tratado de fusionar datos y a su vez algoritmos para realizar acciones de monitoreo y diagnóstico, y aunque no necesariamente se han analizado fallas en cadenas cinemáticas se ha conseguido incrementar la confiabilidad en el diagnóstico (Valtierra-Rodríguez et al., 2013 b). Al respecto ya existen investigaciones interesantes que han utilizado la fusión de datos, un trabajo enfocado a ello es el de Safizadeh y Latifi (2014) quienes propusieron una nueva metodología para el diagnóstico de fallas en rodamientos utilizando señales de vibración y celdas de carga, y para realizar el diagnóstico de fallas en rodamientos fusionan indicadores obtenidos de un análisis

en el tiempo con los indicadores del análisis en frecuencia; estos indicadores los calculan para cada una de las señales y con una técnica de clasificación supervisada obtienen el diagnóstico de fallas, la técnica empleada es muy buena pero su estudio se vio limitado por solo cubrir fallas simples en rodamientos. Otro trabajo con enfoque diferente en el que se fusionan algoritmos es el de Ertunc et al. (2013) en el cual fusionaron dos AG's para el diagnóstico y detección de fallas en rodamientos, y así con una NN y un sistema adaptivo de inferencia neuro-difusa (Adaptive Neuro-Fuzzy Inference Systems-ANFIS) basados en indicadores de corriente y vibraciones realizan la toma de decisiones en el diagnóstico del estado del sistema; en su estudio solo abordaron las fallas típicas que aparecen en rodamientos, este trabajo pudo haber sido más interesante si hubieran probado la combinación de fallas. Así como estas estructuras de diagnóstico existen otras similares, como la de Banerjee y Das (2012) quienes desarrollaron una fusión de técnicas para determinar fallas en rodamientos, para precisar si existía o no falla en el rodamiento realizaron una descomposición empleando EMD a señales de vibración que obtuvieron experimentalmente, y con una estructura basada en SVM clasificaron el tipo de falla del rodamiento, aunque hacen una buena comparativa y validación de sus resultados el estudio se vio limitado al análisis de fallas clásicas en rodamientos.

El tema de análisis de múltiples fallas ha impulsado a investigadores a desarrollar estrategias de condición de monitoreo para su diagnóstico, tanto así que ya existen algunos trabajos que se han centrado en analizar la aparición de múltiples fallas; y aunque se ha abordado este tema aún hay temática sin abordar, como el efecto de las fallas en la cadena cinemáticas. En este sentido, un trabajo interesante con una buena visión es el de Garcia-Perez et al. (2011) quienes desarrollaron una estrategia para condiciones de monitoreo de un motor de inducción, ellos utilizan señales de vibración y de corriente del motor, y en su procesamiento emplean un filtro de respuestas infinitas de alta resolución espectral basado en un clasificador de señales múltiples que usan para la identificación precisa de fallas y valoración del sistema, con su técnica de procesamiento son capaces de detectar fallas ocasionadas por rodamientos y barras rotas; parte interesante de este trabajo es que manejan la combinación de fallas y sus resultados muestran precisión en el diagnóstico, tal vez esta técnica pueda incrementar el nivel de precisión y confiabilidad en el diagnóstico mediante algoritmos inteligentes para determinar de manera automática la condición del sistema.

Finalmente, y como se presentó, existe una gran cantidad de trabajos e investigaciones que se han centrado en desarrollar metodologías y técnicas para la detección de fallas en los componentes de una cadena cinemática, de aquí hay que resaltar que la mayoría de trabajos reportados abordan el estudio de fallas simples, y que además los análisis incluidos en sus estrategias de condición de monitoreo y diagnóstico están basados en señales de vibraciones, corrientes de estator, emisión acústica y temperatura. Poner en práctica acciones de condición de monitoreo y diagnóstico es uno de los nuevos retos que esta ganado importancia por asegurar la condición de trabajo de la maquinaria y operación de los procesos industriales, es por eso que en este trabajo se propone desarrollar metodologías basadas algoritmos inteligentes y fusión de datos, para el monitoreo, diagnóstico y detección de múltiples fallas en cadenas cinemáticas.

Así, el desarrollo de este trabajo buscará como contribución científica la propuesta y desarrollo de dichas metodologías que mejoren la confiabilidad en el diagnóstico de múltiples fallas, y esto desde un punto de vista tecnológico permitirá proponer acciones de mantenimiento predictivo para evitar fallos en el sistema. Además, otra de las contribuciones científicas es demostrar que mediante estas metodologías basadas en fusión de datos es posible analizar la repercusión que genera una falla sobre el resto de los elementos en una cadena cinemática. Con la finalidad de clarificar el termino de cadena cinemática en la Figura 4 se muestra un sistema compuesto por elementos mecánicos y eléctricos, los elementos que componen este sistema son un motor de inducción, una caja de engranes, un generador de DC usado como carga y sus respectivos acoplamientos mecánicos, y la interconexión que existen entre estos elementos se denomina cadena cinemática.




Figura 4. Cadena cinemática formada por elementos mecánicos y eléctricos.

### **1.1.5 Efectos que generan las fallas en cadenas cinemáticas y la confiabilidad en el monitoreo y diagnóstico**

Los elementos de cadenas cinemáticas están expuestos a sufrir algún tipo de falla en cualquier momento, y esto podría ocasionar que no solo un elemento se dañe, también podrían dañarse el resto de los elementos por existir una interconexión que los asocia; más aún, se podría ocasionar un funcionamiento inapropiado en toda la cadena cinemática que puede afectar en algún proceso definido, ejemplo de esto es el trabajo de Walker et al. (2014), quienes utilizaron una máquina de simulación de fallas para la identificación de desbalance y determinaron que este tipo de falla incrementa los niveles de vibración en toda su cadena cinemática.

Se puede decir que realizar acciones de monitoreo y diagnóstico de una cadena cinemática es una tarea sencilla, sin embargo, si no se cuenta con el conocimiento suficiente se podría dar una mala evaluación del estado en el cual se encuentra la cadena cinemática, es por esto que para ejecutar acciones de condición de monitoreo y diagnóstico se debe de contar con herramientas teóricas bien justificadas que ayuden a la toma de decisiones y que además le den confiabilidad al diagnóstico de fallas, ejemplo de esto es el trabajo de Zhang et al. (2013 a) quienes proponen un modelo dinámico no lineal para representar a un sistema de engranes, y a partir de una formulación matemática para simular dicho sistema de engranes y generar señales de aceleración (vibración) determinaron que usar una frecuencia de muestreo inapropiada puede afectar la distorsión de las señales adquiridas; investigaciones como estas sustentan que no se debe pasar por alto la formulación teórica de cualquier fenómeno.

La confiabilidad en el monitoreo y diagnóstico de cadenas cinemáticas implica realizar demasiadas consideraciones, todo con la finalidad de obtener un parámetro o medición que cuantifique que tan confiable es el monitoreo y diagnóstico, ya existen algunos trabajos que hablan de metodologías confiables, tal es el caso de Lin y Chen (2013) quienes mediante la medición estadística de señales de vibración determinaron fallas en rodamientos y solo por comparar sus resultados con los de otras técnicas como WPD y EMD dicen haber obtenido una metodología con un buen grado de confiabilidad. Otro trabajo es el de Jin et al. (2014) utilizan también señales de vibración y con un método estadístico utilizando la Wavelet Morlet y una NN estudiaron fallas en rodamientos, su trabajo destaca por realizar

una comparación con resultados de otros trabajos y decir que con su metodología se puede obtener una excelente precisión en el diagnóstico de fallas que limitaron a rodamientos. Por último, está el trabajo de Uddin et al. (2014) quienes propusieron una metodología de clasificación de fallas para motores de inducción, en donde básicamente convierten señales de vibración a imágenes en 2-D en escala de grises, y con una SVM obtienen la clasificación de fallas de rodamientos, barras rotas y desalineamiento; aunque presentan una técnica interesante de análisis, la forma en como reportan y comprar sus resultados hace que el método de diagnóstico tenga casi un 100% de certeza en la clasificación de fallas en motores de inducción.

Como lo muestra esta sección existen algunos criterios expresados por autores para determinar la confiabilidad en el monitoreo y diagnóstico, solo que algunos utilizan su propio juicio olvidándose de las herramientas estadísticas formales que permitan hacer una evaluación objetiva de sus resultados. Por lo tanto, uno de los objetivos de este trabajo será realizar un análisis de la confiabilidad sustentado con la evaluación y estimación de parámetros estadísticos que indiquen la confiabilidad del monitoreo y diagnóstico de las metodologías que se propondrán para el desarrollo de esta investigación.

## **1.2 Objetivos e hipótesis**

### **1.2.1 Objetivos**

El objetivo de esta tesis es desarrollar metodologías de diagnóstico confiables que estén basadas en algoritmos inteligentes y fusión de datos para mejorar la precisión de acciones condición de monitoreo y diagnóstico de múltiples fallas en una cadena cinemática.

Así, para lograr el objetivo propuesto para esta tesis se han considerado los siguientes objetivos específicos:

- Instrumentar una cadena cinemática con sensores que cuantifiquen señales de vibración, corriente y temperatura, para monitorear y caracterizar las diferentes condiciones de estado evaluadas.
- Realizar una revisión de las técnicas de procesamiento de señales que se han empleado para cálculo de indicadores de falla en sistemas electromecánicos a partir de magnitudes físicas como las vibraciones, corrientes y temperaturas.

- Evaluar el desempeño de las técnicas y estrategias de análisis de indicadores de falla ya existente que se basen en la fusión de datos para, adecuar aquellas que ofrezcan mejores resultados en nuevas metodologías de diagnóstico e identificación de fallas.
- Revisar y evaluar algoritmos y técnicas inteligentes de clasificación que puedan ser incluidas en esquemas de monitoreo y diagnóstico para la detección automática de fallas.
- Hacer una evaluación de la confiabilidad que ofrecen las metodologías de diagnóstico de fallas propuesta para establecer el grado de certeza de los resultados.

### **1.2.2 Hipótesis**

En este trabajo se han propuesto las siguientes hipótesis con el objetivo de abordar la problemática que existe en relación con el monitoreo y diagnóstico de múltiples fallas en cadenas cinemáticas, y además la propuesta de estas hipótesis sirven como un punto de partida para el desarrollo de este trabajo de investigación:

- Mediante algoritmos inteligentes y fusión de datos es posible desarrollar metodologías que permitan mejorar la confiabilidad en el monitoreo y diagnóstico de múltiples fallas en cadenas cinemáticas respecto a los reportados en investigaciones ya realizadas.
- Con la consideración de diferentes magnitudes físicas como vibraciones, corrientes y temperaturas se podrá obtener una caracterización más precisa de las diferentes condiciones de estado respecto a las caracterizaciones clásicas que usan solo una magnitud física, y por lo tanto se mejorarán las capacidades de diagnóstico de fallas de la cadena cinemática.
- La aplicación apropiada de algoritmos de clasificación inteligentes y estrategias de fusión de datos en metodologías para monitoreo y diagnóstico permitirá no solo hacer la identificación de múltiples en cadenas cinemáticas, sino que también permitirán analizar la aparición de fallas en diferentes condiciones de operación.

### **1.3 Justificación**

La mayoría de aplicaciones de la industria moderna utiliza maquinaria especializada en sus procesos de producción, y la composición de estas máquinas está

principalmente basada en cadenas cinemáticas. Esta es una de las principales razones que han impulsado a el desarrollo de este trabajo de investigación, además de que hasta la fecha y de acuerdo con los antecedentes no se han reportado metodologías que estén basados en algoritmos inteligentes y técnicas de fusión de datos que realicen el monitoreo, diagnóstico y detección de múltiples fallas en cadenas cinemáticas. En este sentido, abordar el tema de monitoreo y diagnóstico múltiples fallas, es también una buena oportunidad para estudiar los efectos que generan la aparición de fallas sobre todos los elementos que componen la cadena cinemática, porque ya ha sido probado que una falla afecta y genera repercusiones sobre el resto de componentes que se encuentren relacionados con el elemento de falla (Granados-Lieberman et al., 2013). Por lo tanto, el desarrollo de metodologías e instrumentos que ayuden en el monitoreo de procesos beneficia al sector industrial en diferentes aspectos, por ejemplo: se podrán detener procesos ante la aparición incipiente de fallas y así se evitaren daños mayores, con esto se logrará una reducción de costos al implementar acciones de mantenimiento correctivo, y además la aplicación adecuada de acciones de mantenimiento permitirá alargar la vida útil de maquinaria asegurando su disponibilidad. Con esta contribución se mejorarán aspectos en la confiabilidad, precisión del diagnóstico y costo respecto a las metodologías y técnicas propuestas a la fecha.

Desarrollar investigaciones que involucren el desarrollo de metodologías para el monitoreo y diagnóstico de fallos en cadenas cinemáticas es una de las tantas áreas de aplicación en la que se puede hacer uso de algoritmos inteligentes y la fusión de datos. La importancia de efectuar el monitoreo de estos sistemas se debe a que son parte principal de la maquinaria en procesos de la industria, y la aparición repentina de fallas se hace inherente a la operación de las máquinas por estar expuestas a largos periodos de operación. Esta situación demanda a seguir contribuyendo con creación de nuevas metodologías que permitan realizar el monitoreo y diagnóstico de cadenas cinemáticas para establecer su condición de operación. Hasta ahora las soluciones obtenidas ante esta problemática son de artículos publicados en congresos internacionales y revistas indexadas en los cuales se presentan metodologías basadas en procesamientos con solo una señal, algunos trabajos si han utilizado algún algoritmo inteligente pero la mayoría enfoca sus estudios en fallas simples; así, la solución demandada ante esta problemática es la creación de metodologías de monitoreo y diagnóstico capaces de analizar múltiples fallas en una cadena cinemática.

Por otra parte, también ya existen instrumentos disponibles en la empresa Fluke por ejemplo que ayudan el monitoreo de sistemas, pero presentan desventajas como: alto costo, complejidad por entender sus algoritmos y técnicamente su arquitectura es cerrada ya que solo permiten estimar el estado de las máquinas dejando fuera opciones de realizar el monitoreo; en este sentido, con la creación de metodologías de monitoreo y diagnóstico basadas en algoritmos inteligentes y fusión de datos no se realizaría la detección de fallas únicamente en cadenas cinemáticas, sino que además, debido al uso de diferentes magnitudes físicas, estas metodologías tienen la ventaja de poder exportarse y adecuarse para realizar el monitoreo y diagnóstico de otros sistemas.

Otro factor que impulsa el desarrollo de metodologías aplicadas al monitoreo y diagnóstico de fallas en cadenas cinemáticas es la carencia de éstas en áreas como la de algoritmos inteligentes y fusión de datos, el diseño de metodologías de este tipo permitirá de forma eficiente y versátil mejorar la confiabilidad y el nivel de precisión en el monitoreo, diagnóstico y detección de fallas múltiples en sistemas integrados por cadenas cinemáticas, con esto, la contribución en la innovación pretende ser el desarrollo de metodologías basadas en algoritmos inteligentes y la fusión de datos que permita detectar múltiples fallas en toda la cadena cinemática ya que hasta hoy no existe una metodología que se le parezca.

#### 1.4 Planteamiento general

La propuesta para el desarrollo de metodologías de monitoreo y diagnóstico de múltiples fallas en cadenas cinemáticas se muestra en el diagrama de la Figura 5, en el cual se pueden apreciar las diferentes etapas las que deben atenderse.

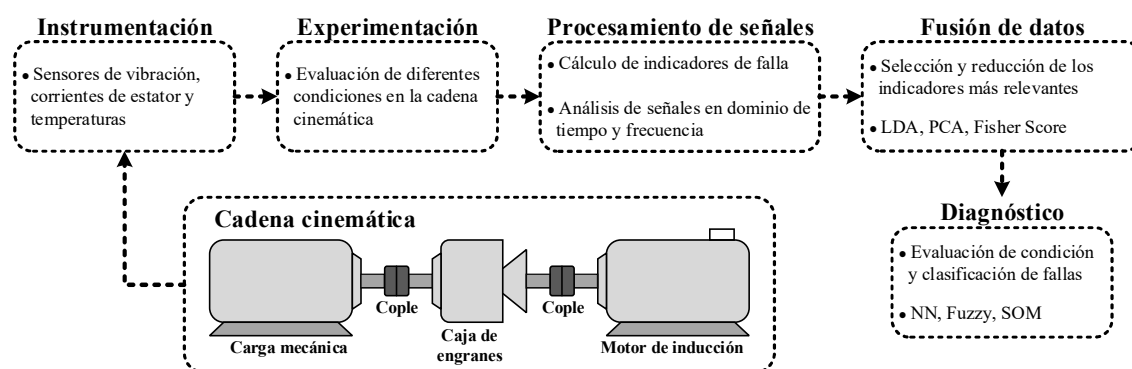


Figura 5. Planteamiento general del proyecto para desarrollar una metodología de monitoreo y diagnóstico de múltiples fallas en una cadena cinemática.



- Instrumentación, la cadena cinemática sobre la cual se evaluarán diferentes condiciones de estado se compondrá de un motor de inducción, una caja de engranes, un generador que es usado como carga mecánica y los acoplamientos mecánicos requeridos para su interconexión. Esta cadena cinemática será instrumentada con diferentes sensores que permitan cuantificar diferentes magnitudes físicas como vibraciones, corrientes y temperaturas.
- Experimentación, se evaluarán experimentalmente diferentes condiciones en la cadena cinemática, la caja de engranes y el motor de inducción serán los elementos de la cadena cinemática sobre los cuales se evaluarán diferentes condiciones de estado.
- Procesamiento de señales, cada una de las condiciones evaluadas estará representada por señales de diferente magnitud física; así, durante la etapa de procesamiento se realizará el cálculo de indicadores de falla con el objetivo de obtener un conjunto de indicadores que caractericen a cada una de las condiciones evaluadas. Para el cálculo de indicadores se emplearán técnicas de procesamiento de señales de análisis en el tiempo, frecuencia y tiempo-frecuencia.
- Fusión de datos, después de efectuar el cálculo de indicadores característicos de falla y previo a su fusión, estos indicadores serán sometidos a un análisis para determinar cuáles son aquellos indicadores que contienen información representativa de cada una de las condiciones, este análisis se realizara empleando técnicas de selección de indicadores. Después, los indicadores seleccionados se fusionarán a través de técnicas de extracción de indicadores, y mediante esta extracción se indicadores se obtendrá una representación de las diferentes condiciones de estado consideradas en un espacio definido.
- Diagnóstico, la condición de estado de la cadena cinemática estará descrita por el conjunto de indicadores extraídos durante el proceso de selección y reducción, estos indicadores serán evaluados mediante algoritmos inteligentes de clasificación para establecer la condición de estado actual bajo cual se encuentra la cadena cinemática; así, en esta etapa de diagnóstico se buscará generar respuestas precisas en la detección y clasificación de múltiples fallas.

# Capítulo II

## 2. Fundamentación teórica

Con el objetivo de desarrollar e implementar una metodología de condición de monitoreo y diagnóstico de fallas en cadenas cinemáticas, se realizó una revisión de los diferentes aspectos teóricos y consideraciones que se deben de tener. Por lo tanto, en este capítulo se presentan aspectos teóricos relacionados con la implementación de la metodología de diagnóstico propuesta y que se desarrolla en esta tesis, con especial atención en teoría, técnicas y algoritmos cuya principal tarea se enfoca en el diagnóstico de fallas.

### 2.1 Fallas en cadenas cinemáticas

#### 2.1.1 Rodamientos dañados

La mayoría de las máquinas eléctricas y mecánicas utilizan algún tipo de rodamiento, estos rodamientos son usados para unir la parte fija de las máquinas con las partes giratorias, y así permitir un movimiento rotacional libre de rotores en motores de inducción y de ejes en cajas de engranes.

Los rodamientos son elementos giratorios con tolerancias extremadamente pequeñas para evitar desplazamientos internos, excepto el rotacional; básicamente su estructura consta de una pista/anillo exterior, una pista/anillo interior, una canastilla/jaula y un conjunto de elementos rodantes, en la Figura 6 se muestra un rodamiento de bolas. Aun bajo condiciones normales de operación con cargas balanceadas y buenas alineaciones, la degradación en rodamientos generalmente se puede generar por fatigas mecánicas, esfuerzos internos, excentricidad inherente, descargas de corriente por el uso de variadores de frecuencia; también causas externas como la contaminación de lubricante y corrosión pueden generar fallas en rodamientos.

Existe una gran variedad y tipos diferentes de rodamientos, pero cada uno tiene bien definidas sus propias dimensiones, gracias a esto y debido a que los rodamientos son elementos mecánicos rotatorios, es posible conocer las frecuencias características para cada uno de los elementos que componen a un rodamiento. Por lo tanto, si un rodamiento presenta algún tipo de falla en cualquiera de sus elementos, se generarán impulsos a la frecuencia

característica del elemento dañado en el rodamiento. Estas frecuencias características de los elementos de un rodamiento también pueden conocerse frecuencias características de falla, y son definidas como: frecuencias de falla de la pista interior y exterior ( $f_{BPIF}$ ,  $f_{BPOF}$ ), frecuencia de falla de la jaula ( $f_{FTF}$ ) y la frecuencia de falla de los elementos rodantes ( $f_{BSF}$ ), y sus expresiones correspondientes son las siguientes (Garcia-Perez et al., 2011):

$$f_{BPIF} = \frac{f_r}{2} N_b \left( 1 + \frac{D_B}{D_C} \cos \theta \right) \quad (2.1)$$

$$f_{BPOF} = \frac{f_r}{2} N_b \left( 1 - \frac{D_B}{D_C} \cos \theta \right) \quad (2.2)$$

$$f_{FTF} = \frac{f_r}{2} \left( 1 - \frac{D_B}{D_C} \cos \theta \right) \quad (2.3)$$

$$f_{BSF} = \frac{D_C}{2D_B} f_r \left( 1 - \left( \frac{D_B}{D_C} \right)^2 (\cos \theta)^2 \right) \quad (2.4)$$

donde  $f_r$  es la frecuencia de rotación a la que gira la pista interior,  $D_c$  es el diámetro de la jaula medido desde un centro de bola al centro de bola opuesta,  $D_B$  es el diámetro de las bolas,  $N_B$  es el número de bolas y  $\theta$  es el ángulo de contacto entre el cojinete superficies.




Figura 6. Rodamiento de bolas y sus partes.

Estas frecuencias de fallo pueden ser utilizadas en análisis espectral de vibraciones para la detección de fallas en rodamientos; además, el efecto vibratorio que generan estas frecuencias características de falla en rodamientos afecta a las corrientes de estator a frecuencias predecibles y relacionadas con las frecuencias de falla características y la frecuencia de alimentación  $f_s$ . En la siguiente expresión,  $f_{BE}$  representa la relación que existe entre los efectos de vibración y la componente característica de falla ( $f_{BPOF}$ ) en las corrientes de estator; así, mediante la identificación de la componente  $f_{BE}$  y sus armónicos sobre

espectros de señales de corriente, se puede hacer la identificación de fallas en rodamientos (Bellini et al., 2008).

$$f_{BE} = f_s \pm kf_{BPOF} \quad k = 1,3,5, \dots \quad (2.5)$$

### 2.1.2 Fallas en rotores por barras rotas

Las barras rotas en los devanados del rotor es una de las fallas más comunes en motores con jaula de ardilla, donde una barra o más pueden estar parcialmente o completamente rotas. El daño de barras rotas se puede generar defectos de manufactura, arranques frecuentes a tensión nominal, esfuerzos térmicos y esfuerzos mecánicos generados por rodamientos.

Comúnmente este tipo de falla genera anomalías en el campo magnético del entrehierro produciendo una componente armónica que se inyecta directamente en las líneas de alimentación. Para fines de diagnóstico, esta componente armónica de falla por barras rotas ( $f_{brb}$ ) ha sido considerada para detectar anomalías en motores de inducción, debido a que esta componente modificará el patrón del espectro de corriente asociada con la condición sana del motor de inducción. Esta componente característica de falla por barras rotas  $f_{brb}$  que está relacionada principalmente a la frecuencia fundamental de alimentación  $f_s$  dada por (2.6), está, donde  $p$  es el número de polos del motor,  $s$  es el deslizamiento del motor en operación y  $k/p$  denota los valores característicos de los armónicos de falla en el motor.

$$f_{brb} = \left( \frac{(1-s)k}{p} \pm s \right) f_s \quad \frac{k}{p} = 1,3,5, \dots \quad (2.6)$$

Una simplificación en la formulación para obtener la componente armónica de falla por barra rota se puede obtener sustituyendo  $k/p=1$ . Esta componente de falla producirá oscilaciones en la velocidad de giro del rotor, esto origina una nueva familia de componentes de falla dadas por:

$$f_{brb} = (1 \pm 2ks)f_1 \quad k = 1,3,5, \dots \quad (2.7)$$

Aunque las barras rotas no causan fallas inmediatas en motor con jaula de ardilla, estas pueden causar serios problemas debido a sus efectos secundarios como:

sobrecalentamiento, excentricidades en el rotor, daños en el aislamiento del motor y consecuentemente falla en el devanado (Garcia-Ramirez et al., 2012).

### **2.1.3 Fallas de excentricidad y desalineamiento**

En general para cualquier máquina rotatoria, la excentricidad o desbalance se genera cuando el eje de rotación de la máquina no corresponde con su centro de masa, y este fenómeno generara fuerzas armónicas que actúan perpendicularmente al eje de rotación. En motores eléctricos comúnmente suele aparecer excentricidades del entrehierro, y esta condición se genera cuando existe una desigualdad entre el estator y el rotor; este tipo de excentricidad desbalancea la tracción magnética provocando vibraciones, mayor ruido, desgaste en rodamientos y deflexión en el rotor. Las causas que generan excentricidad en cualquier tipo de máquina están relacionadas con errores de manufactura, desgaste en rodamientos, desalineación de ejes, deformaciones térmicas, entre otras. La excentricidad se puede convertir en un caso muy crítico de falla cuando la frecuencia de rotación coincide específicamente con alguna de las frecuencias naturales del sistema, esto podría generar el fenómeno de resonancia (Esfahani et al., 2014).

Por otra parte, la condición de desalineamiento en máquinas rotatorias se genera cuando las líneas centrales de un par de ejes acoplados no coinciden entre sí, este tipo de falla generadora un incremento de las cargas debido a la desalineación que existe entre los ejes, los rodamientos y los acoplamientos mecánicos. El incremento de cargas puede conducir a la disminución de la eficiencia de la maquinaria, e incluso puede mayores daños. Los factores principales que generan la condición de desalineamiento son: asimetría en las cargas aplicadas, asentamiento desigual de la cimentación, montaje incorrecto de las máquinas, entre otras. Por lo tanto, un buen conocimiento acerca de las vibraciones del eje del rotor puede ser el elemento clave para el diagnóstico y análisis de la desalineación en las máquinas giratorias (Verucchi, et al., 2016).

### **2.1.4 Fallas en engranes**

El uso de cajas de engranes en diferentes aplicaciones industriales se está incrementando por la necesidad de manejar diferentes velocidades de rotación y mantener torques específicos entre las máquinas eléctricas y la carga mecánica. Existen diferentes tipos de cajas de engranes que pueden ser caracterizadas por el uso de engranes rectos, helicoidales,

cónicos y de gusano; en todas las cajas de engranes hay por lo menos un par de engranes (conductor y conducido), también pueden existir cajas de engranes con múltiples etapas de reducción.

Debido a que las cajas de engranes utilizan elementos rotatorios, la aparición de cualquier tipo de falla sobre alguno de los engranes generara impactos provocando la aparición de vibraciones. En este sentido, las vibraciones en maquinaria rotativa con engranajes serán inherentes a su funcionamiento porque éstas se generan debido al juego mecánico o la excitación de las fuerzas dinámicas inducidas cuando los dientes de engranaje entran en contacto; por consiguiente, a mayor juego mecánico entre dientes de engrane, la amplitud de la vibración es mayor (Lozano y Jáuregui, 2013). Además, las variaciones de velocidad y carga también contribuyen a las vibraciones en los sistemas con engranajes, cuando los dientes entran en contacto produciendo una frecuencia de impacto denominada frecuencia de engranaje ( $f_m$ ) y es la frecuencia característica en la que par de engranes inducirá vibraciones. La frecuencia de engranaje para un par de engranes se calcula mediante:

$$f_m = N \cdot f_r \quad (2.8)$$

donde  $N$  es el número de dientes y  $f_r$  es la frecuencia de rotación del eje de entrada o de salida del engrane analizado. Es útil observar que varias frecuencias de engranaje de engranajes están presentes en un tren de engranajes complejo (Mark 2015, Norton y Karczub 2003, Jauregui-Correa y Gonzales 2009).

La falla más común en cajas de engranes es la de irregularidades discretas en los dientes de sus engranes como un diente roto o fracturado. Ante este tipo de fallas, se genera un aumento de los niveles de ruido y vibraciones a la frecuencia de rotación del eje del engrane dañado, y también en sus correspondientes armónicos asociados. Estos picos de frecuencia se suman a la frecuencia de engranaje y a sus armónicos. Para una caja de engranes en buenas condiciones, sobre un espectro de frecuencias de vibraciones se pueden identificar las frecuencias de los ejes de entrada y salida de la caja de engranes, la frecuencia de engranaje, un conjunto de bandas laterales que acompañan a la frecuencia de engranaje ( $f_{sideband}$ ) y los respectivos armónicos de la frecuencia de engranaje. En la Figura 7a se muestra un espectro de vibraciones teórico para una caja de engranes en condición sana.

$$f_{sideband} = f_m \pm f_r \quad (2.9)$$

Comúnmente, estas bandas laterales se generan por la modulación de la forma de onda del engranaje de los dientes debido a la rotación de los engranes. Cuando los dientes están en buenas condiciones y los engranes son concéntricos, la amplitud de  $f_m$ ,  $f_{sideband}$  y sus armónicos serán bajas. Por otro lado, un aumento de amplitud en el  $f_m$ ,  $f_{sideband}$  y sus armónicos está asociada con la aparición de desgaste uniforme en los engranes.

En la Figura 7b se muestra un espectro de vibraciones teórico de una caja de engranes bajo la influencia de desgaste en los engranes. Puesto que, para un par de engranajes  $f_m$  es la misma, la información de  $f_{sideband}$  permite saber cuál es el engranaje desgastado; esto se determina ya que cada engranaje tiene diferentes  $f_r$ .

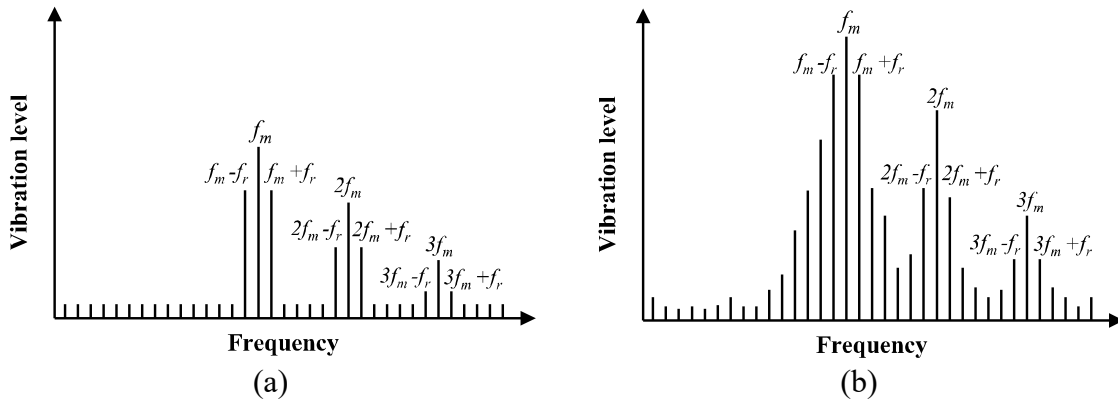


Figura 7. Espectro de vibraciones de una caja de engranes en estado: (a) sano y (b) desgaste de engranes.

## 2.2 Cálculo de indicadores

El cálculo de indicadores es el procedimiento que se aplica justo después de la adquisición de señales físicas, este procedimiento es esencial para transformar y procesar la información de señales a variables que se puedan interpretar. A pesar de que es un paso esencial, mucha de las veces se llega a convertir en uno de los pasos más difíciles, debido a la información irrelevante que pueden incluir las señales analizadas. Por lo tanto, con la aplicación de la etapa de cálculo de indicadores para realizar acciones de condición de monitoreo y diagnóstico, se analiza la información de las magnitudes físicas adquiridas durante el monitoreo para resaltar la información más relevante que contienen. También, antes del cálculo de indicadores se pueden emplear diferentes procesamientos de señales para

hacer la representación de los datos en diferentes formas. Por lo tanto, el principal objetivo del cálculo de indicadores es realizar un análisis de las magnitudes físicas para transformarlas en información que se pueda interpretar, y así obtener un conjunto de indicadores relacionados con las fallas. Las técnicas de procesamiento de señales basadas en el análisis de dominio en tiempo, frecuencia y tiempo-frecuencia han sido las más utilizadas durante el cálculo de indicadores en esquemas de condición de monitoreo y diagnóstico (Duda et al., 2000).

### **2.2.1 Técnicas de análisis de señales basadas en el dominio del tiempo**

Las técnicas de dominio en el tiempo son de las más efectivas para el análisis de señales en estado estacionario, y también algunas veces llegan a ser empleadas para señales en estado no estacionario. El cálculo de indicadores generalmente se realiza a partir de análisis de señales en el dominio del tiempo, este tipo de indicadores proporcionan información básica relevante de las señales en el tiempo, la información proporcionada puede estar relacionada con la forma de la señal, sus tendencias, amplitudes y rangos de frecuencia, entre otros. Debido al bajo costo computacional que representa hacer el cálculo de indicadores estadísticos, esta es la forma más sencilla de realizar un procesamiento sobre señales adquiridas. Dentro de las técnicas de análisis de dominio del tiempo, además de incluir métodos estadísticos y estocásticos, también se pueden emplear técnicas de filtrado de datos, promedio de tiempo sincrónico y otros. En la Tabla 2.1 se enlistan los principales indicadores estadísticos que han sido empleados para para el cálculo de indicadores de falla en esquemas de condición de monitoreo y diagnóstico; estos indicadores estadísticos han sido empleados satisfactoriamente en estrategias de condición de monitoreo y diagnóstico de fallas en cadenas cinemáticas (Delgado-Prieto et al., 2013; Igba et al., 2016).

### **2.2.2 Técnicas de análisis de señales basadas en el dominio de frecuencia**

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



Tabla 2.1 Indicadores estadísticos utilizados en el análisis de señales de dominio del tiempo.

Indicador	Ecuación
Media	$\bar{x} = \frac{1}{n} \cdot \sum_{k=1}^n  x_k $ (2.10)
Valor máximo	$\hat{x} = \max(x)$ (2.11)
Root mean square	$RMS = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k)^2}$ (2.12)
Square root mean	$SRM = \left( \frac{1}{n} \cdot \sum_{k=1}^n \sqrt{ x_k } \right)^2$ (2.13)
Desviación estándar	$\sigma = \sqrt{\frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2}$ (2.14)
Varianza	$\sigma^2 = \frac{1}{n} \cdot \sum_{k=1}^n (x_k - \bar{x})^2$ (2.15)
RMS Factor forma	$SF_{RMS} = \frac{RMS}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$ (2.16)
SRM Factor forma	$SF_{SRM} = \frac{SRM}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$ (2.17)
Factor cresta	$CF = \frac{\hat{x}}{RMS}$ (2.18)
Factor latitud	$LF = \frac{\hat{x}}{SRM}$ (2.19)
Factor impulso	$IF = \frac{\hat{x}}{\frac{1}{n} \cdot \sum_{k=1}^n  x_k }$ (2.20)
Skewness	$S_k = \frac{E[(x_k - \bar{x})^3]}{\sigma^3}$ (2.21)
Kurtosis	$k = \frac{E[(x_k - \bar{x})^4]}{\sigma^4}$ (2.22)
5° momento	$5thM = \frac{E[(x_k - \bar{x})^5]}{\sigma^5}$ (2.23)
6° momento	$6thM = \frac{E[(x_k - \bar{x})^6]}{\sigma^6}$ (2.24)

transformada de Fourier (Fast Fourier Transform-FFT) es una de las técnicas más conocidas que se emplea para el análisis en dominio de frecuencia, el principio básico de la FFT es que cualquier señal arbitraria puede ser descompuesta en conjuntos de senoidales de diferentes frecuencias. En este sentido, un espectro de frecuencias obtenido a través la FFT se genera al proyectar una señal temporal en un conjunto de funciones básicas, donde cada uno de estos términos es una función senoidal con un único valor. Por lo tanto, cada uno de estos valores componen a la FFT (o el espectro de frecuencias) de la señal (Bediaga et al., 2013).

En muchas de las metodologías de diagnóstico de fallas para máquinas rotatorias basadas en análisis del dominio de frecuencia, o análisis todo el espectro de frecuencias, o analizan algunas componentes de frecuencia específicas, para obtener indicadores característicos de las señales.

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

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-2\pi t f} dt \quad (2.25)$$

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

$$X[k] = \sum_{i=0}^{N-1} x_i e^{-j2\pi k \frac{i}{N}} \quad (2.26)$$

La DFT se calcula sobre un número finito de muestras temporales  $N$  de una señal discreta  $x_i$  con  $i=0, \dots, N-1$ , para obtener una aproximación espectral. Así como para señales de dominio en el tiempo, las señales espectrales también pueden ser caracterizadas por indicadores estadísticos de frecuencia, y estos indicadores después son aplicados en acciones de condición de monitoreo y diagnóstico. Además de los indicadores estadísticos, existen indicadores característicos de falla para la mayoría de elementos rotatorios de las máquinas rotatorias (Rao et al., 2011).

### 2.2.3 Técnicas de análisis de señales basadas en el dominio de tiempo-frecuencia

Las técnicas de procesamiento de señales basadas en el análisis de dominio de tiempo-frecuencia son un enfoque alternativo que trata de abordar las limitaciones y problemas de las técnicas de análisis basadas en el dominio del tiempo y frecuencia. Así como su nombre lo dice, las técnicas de análisis basado en dominio tiempo-frecuencia, describen de forma simultánea, el tiempo y componentes frecuenciales de las señales. Estas técnicas son de gran utilidad en aquellos casos donde la maquinaria está sujeta a cambios transitorios de la velocidad, donde la FFT ya no es tan efectiva. Para el análisis de señales a

partir de técnicas en el dominio tiempo-frecuencia se emplean distribuciones que pueden representar la energía, o la potencia de una señal en un espacio bidimensional de tiempo y frecuencia. Por lo tanto, una representación en el dominio tiempo-frecuencia, muestran como el contenido frecuencial varia a lo largo del tiempo. Existen diferentes técnicas que pueden ser empleadas para realizar un análisis en el dominio tiempo-frecuencia, entre las más conocidas están la transformada corta de Fourier (Short Time Fourier Transform-STFT), transformadas continuas con Wavelets, distribuciones Wigner-Ville, entre otras. (Gallego y Castro, 2011; Rao et al., 2011).

#### **2.2.4 Técnicas de análisis de señales basadas en descomposiciones**

Las técnicas basadas en la descomposición de señales son consideradas técnicas de análisis en el dominio tiempo-frecuencia; existen diferentes técnicas que pueden realizar procesamiento de señales desde el punto de vista de descomposición de la señal. Este tipo de técnicas se enfocan en descomponer una señal en diferentes subconjuntos que contengan las partes esenciales de la señal original; aunque, estas técnicas no se enfocan en obtener una representación de las componentes frecuenciales a lo largo del tiempo, enfatizan aquellos conjuntos de frecuencias o funciones temporales más significativos de la señal analizada. En este sentido, la técnica de descomposición por modos empíricos y la descomposición utilizando Wavelets son de los enfoques más representativos y utilizados en esquemas de condición de monitoreo y diagnóstico (Van y Kang, 2015).

- **Descomposición de modos empíricos:**

El método de descomposición por modos empíricos es un método adaptativo y eficiente que fue introducido por Huang et al. (1998) para la descomposición de señales no lineales y no estacionarias en funciones de modo intrínseco. Este enfoque de análisis de señales es relativamente nuevo, y se derivó de la idea de que los extremos locales entrelazados y los cruces por cero pueden representar características de los datos.

El proceso para realizar la descomposición de la señal y obtener el conjunto de funciones intrínsecas se conoce como "tamizado"; el cual consiste en:

- Identifican todos los máximos y mínimos locales de la señal y hacer la conexión de cada uno de los máximos y los mínimos locales mediante interpolación utilizado curvas spline cubicas para generar los envolventes superiores e inferiores.

- Calcular los valores medios sobre el envolvente superior e inferior  $m_I$ , y la primera componente  $h_I$  es la diferencia entre la señal original  $x(t)$  y  $m_I$ .
- Verificar si  $h_I$  satisface las condiciones y criterios de una función intrínseca, y tomar a este valor como el primer modo intrínseco de  $x(t)$ . Pero si  $h_I$  no es un modo intrínseco, este se considerará como un proto-modo intrínseco y se nombrará como  $h_{II}$ .
- Tomar  $h_{II}$  como la señal original y repetir el procedimiento hasta que  $h_{Ik}$  satisfaga las condiciones de un modo intrínseco, y desligarlo como  $c_I$ ,  $k$  será el número de iteraciones para generar un modo intrínseco.
- Substraer a  $c_I$  de la señal original  $x(t)$ , este residuo esta denotado por  $r_I$ , después se considera a  $r_I$  como la señal original y se repetirá el proceso para encontrar los otros modos intrínsecos.
- El procedimiento de la descomposición de la señal puede detenerse cuando  $r_n$  se convierta en una función monótona de la cual no se puede extraer más modos intrínsecos. Sin embargo, es bien sabido que sólo un número determinado de modos intrínsecos tiene significado físico, por lo cual sólo será necesario considerar un número específico de modos intrínsecos para extraer la información más relevante de la señal original.

Al final del proceso, la señal original puede ser reconstruida mediante la suma de todos los modos empíricos y el residuo final, esto es (Huang et al., 1998):

$$x(t) = \sum_{i=1}^n c_i(t) + r_n \quad (2.27)$$

### 2.3 Reducción de indicadores

El conjunto de indicadores calculados para la caracterización de las condiciones de operación de la maquinaria juega un papel muy importante en los esquemas de condición de monitoreo y diagnóstico, y el rendimiento de estos esquemas durante el proceso de diagnóstico de fallas se puede ver comprometido por el uso de indicadores inapropiados que contienen información no representativa a las diferentes condiciones.

Sin embargo, aunque, se cree que el uso de un gran número de indicadores puede incrementar las capacidades de discriminación entre fallas, este aumento del número de

indicadores no asegura la adición de información relevante y relacionada con las diferentes condiciones de funcionamiento. Por esta razón, diferentes estrategias y procedimientos relacionados con la reducción de indicadores han sido propuestas para ser incluidas en los esquemas de condición de monitoreo y diagnóstico. En este sentido, independientemente de si los esquemas de condición de monitoreo y diagnóstico son empleados para evaluar la condición de operación de máquinas eléctricas o mecánicas, las principales estrategias de reducción de indicadores incluidas son la selección de indicadores y la extracción de indicadores (Li et al., 2015; Theodoridis y Koutroumbas. 2006).

### **2.3.1 Selección de indicadores**

El proceso de selección de indicadores se realiza con el objetivo de reducir el número de indicadores originales establecidos mediante la selección de aquellos que contengan la información más representativa. Comúnmente se evalúa a cada uno de los indicadores de forma individual o en subconjuntos bajo una función objetivo o criterio de evaluación, existen dos tipos de técnicas empleadas en la selección de indicadores, las técnicas de filtrado y las de envoltura.

En las técnicas basadas en filtros, cada indicador es evaluado independientemente para asignarle una clasificación entre todos los indicadores. En esta técnica de sección se impone un umbral para seleccionar las características más susceptibles de acuerdo a sus capacidades descriptivas individuales. Las técnicas de filtrado no requieren un algoritmo de aprendizaje particular, por lo que se utiliza la heurística para evaluar un subconjunto de indicadores. Además, este tipo de técnicas son generalmente muy eficientes y rápidas de calcular, sin embargo, un indicador que no contiene información discriminativa es útil por sí mismo podría contenerla cuando se combina con otros indicadores, y esto no se considera en este enfoque de selección de indicadores.

Por otra parte, en técnicas basadas en envoltorios, diferentes subconjuntos de indicadores se evalúan repetidamente a través de la validación cruzada con una máquina de aprendizaje específica. Las técnicas de envoltura requieren un algoritmo de aprendizaje predeterminado o una función de evaluación y utilizan el rendimiento para evaluar y determinar qué indicadores se seleccionan. Los métodos de envoltura han sido criticados por ser métodos de fuerza bruta que necesitan gran cantidad de cálculo para cubrir todo el espacio de búsqueda; sin embargo, se obtiene una alta precisión. De hecho, uno de los métodos más

comunes para la reducción de la dimensionalidad se basa en la selección secuencial de indicadores, en la que se realiza la selección de un subconjunto de indicadores para definir un modelo representativo de la distribución de datos. Los algoritmos de búsqueda secuencial se usan para agregar o quitar indicadores de un subconjunto elegido mientras se evalúa el criterio de selección. Estos métodos se basan en la selección secuencial hacia adelante o la selección secuencial hacia atrás, si el conjunto de indicadores original está inicialmente vacío o lleno, respectivamente. Además, la variante flotante que manejan estos métodos permite eliminar los indicadores que se han agregado o añadir indicadores que se habían eliminado en una iteración anterior. Dicha capacidad flotante aumenta en general el rendimiento del subconjunto de indicadores finales seleccionado.

El procedimiento de selección comienza con un modelo de regresión inicial mediante la inclusión de características del conjunto de indicadores disponibles. Una vez que el modelo está definido, su comparación con variantes del modelo incluyendo o no diferentes subconjuntos de indicadores se realiza secuencialmente. Para ello, se utiliza como criterio de selección un término de error que representa desviaciones de la ecuación de regresión. Varios índices pueden ser utilizados para examinar la precisión del modelo, sin embargo, uno de los más utilizados es el parámetro F-estadístico, sugerido en como un buen indicador de la capacidad general del modelo. Este parámetro se basa en que una observación real es la suma del resultado del modelo y del residuo. Por lo tanto, el error cuadrático medio debido a la regresión,  $MSE_{Regresión}$ , dividido por el error cuadrático medio debido al residuo,  $MSE_{Residual}$ , es el valor F-estadística como se muestra en (Duda et al., 2000; Theodoridis y Koutroumbas. 2006).

$$F = \frac{MSR_{Regression}}{MSE_{Residual}} = \frac{\frac{\sum_i (\hat{y}_i - \bar{y})^2}{q-1}}{\frac{\sum_i (y_i - \hat{y}_i)^2}{n-q}} \quad (2.28)$$

donde  $y$  es la observación real,  $\bar{y}$  es la media,  $\hat{y}$  es el resultado del modelo,  $q$  es el número de coeficientes en el modelo,  $n$  es el número de indicadores e  $i$  es un número entero.

### 2.3.2 Extracción de indicadores

El proceso de extracción de indicadores que es una estrategia con fines de transformación, donde de alguna forma se busca obtener un nuevo subconjunto de indicadores en una dimensión menor a la del conjunto de indicadores original, la

transformación obtenida contiene una combinación del conjunto de indicadores original. Uno de los inconvenientes de las estrategias de reducción de indicadores es que el nuevo conjunto de indicadores no tiene una interpretación comprensible, el sentido de las magnitudes físicas se pierde durante el proceso de reducción; sin embargo, a menudo este tipo de estrategias se abordan para la reducción de indicadores, fusión de información o técnicas de análisis de indicadores. Un conjunto de indicadores con información no correlacionada puede obtenerse mediante la aplicación de técnicas de atracción de indicadores; y aunque, durante el proceso de reducción se pierde la interpretabilidad de las magnitudes físicas, para los sistemas de condición de monitoreo y diagnóstico no representa un problema para continuar con el desarrollo de metodologías de diagnóstico que incluyan técnicas de reducción de indicadores.

Las técnicas de reducción de indicadores se pueden clasificar dependiendo del objetivo que buscan, por lo tanto, existen *técnicas de representación de señales*, donde el objetivo del mapeo de los indicadores extraídos es la representación precisa en un espacio menor; *las técnicas de clasificación*, donde el objetivo de la extracción de indicadores es mejorar la información para la discriminación entre clases en un espacio de menor dimensión. Además, de que para cada uno de estos casos existen las técnicas lineales y no lineales, y la aplicación de cada una de estas dependerá del objetivo que se quiera lograr con la reducción de un conjunto de indicadores (van der Maaten et al., 2008).

- **Análisis de componentes principales**

El análisis de componentes principales (PCA) es una de las técnicas lineales no supervisadas más conocidas empleadas para la reducción de indicadores. El resultado de la aplicación de la técnica PCA sobre un conjunto de indicadores, es un nuevo conjunto de indicadores llamados componentes principales. Donde cada componente principal es una combinación lineal de los indicadores originales. Además, dentro de las componentes principales no hay información redundante por ser ortogonales entre sí; así, gran parte de la información de los datos será conservada en pocas componentes principales, es decir, toda la variabilidad contenida en el conjunto de indicadores originales se representará por el nuevo conjunto de indicadores extraídos (Wan et al., 2016).

La técnica PCA identifica las direcciones ortogonales de covarianza máxima de las observaciones del conjunto original de indicadores (dirección máxima de dispersión de datos), y proyecta estas observaciones en un nuevo espacio dimensional formado por el

mismo número de componentes que de indicadores. Sin embargo, estas componentes puede ser ordenadas de acuerdo a su significancia (de mayor a menor), con esto se puede establecer un umbral para obtener un conjunto final reducido de las componentes de covarianza más altos. Una representación del proceso de reducción de indicadores a través de la PCA se muestra en la Figura 8, y enseguida se realiza su descripción.




Figura 8. Proceso de extracción de indicadores mediante la PCA. (a) Conjunto inicial de indicadores en un espacio 3D. (b) Ubicación de las componentes principales. (c) Representación del conjunto de indicadores extraídos en un espacio 2D.

Con el fin de interpretar la técnica PCA, se puede utilizar un problema inicial: para encontrar un vector  $x_w$  que minimice la suma de las distancias cuadradas entre  $x_w$  y el resto de vectores, para esto se utiliza el criterio de error cuadrado:

$$J_0(x_0) = \sum_{i=1}^N \|x_w - x_i\|^2 \quad (2.29)$$

Siguiendo esta idea, la primera componente principal corresponde al vector mostrado en la Figura 8 que se etiqueta como PC1, para generar estas componentes principales: primero, se calcula la matriz de covarianza para el conjunto completo de observaciones para evaluar la relación entre indicadores. Segundo, se realiza la diagonalización de los modelos de matriz de covarianza y vectores propios  $x_{\lambda-i}$  y valores propios  $\lambda_i$ . Tercero, los vectores propios se ordenan en función de sus valores propios. Los vectores propios que contribuyen menos de un porcentaje especificado en la variación de datos se eliminan del conjunto de componentes principales finales. Por último, los vectores propios más significativos se utilizan para obtener la proyección del conjunto de los indicadores originales, en este sentido, la proyección del conjunto inicial de indicadores sobre el  $i$ -ésimo vector propio se obtiene como (van der Maaten, 2007):



$$Y_i = x_{\lambda-i} * X_i \quad (2.30)$$

- **Análisis discriminante**

Análisis discriminante lineal (LDA) es la técnica de extracción de indicadores supervisada más conocida que se utiliza para la reducción de lineal de la dimensionalidad en problemas en los que se abordan múltiples clases. El principal objetivo de la técnica LDA se encuentra en la búsqueda de una nueva proyección de menor dimensión donde la información más discriminativa entre los puntos de datos pertenecientes a diferentes clases se maximiza (Van y Kang, 2015). Debido a que el LDA es una técnica supervisada, es una técnica apropiada para maximizar el desempeño de metodologías de condición de monitoreo y diagnóstico por identificar un conjunto disponible de condiciones de falla.

De hecho, considerando que la LDA aborda problemas de múltiples clases con  $C$  clases compuestas por  $N$  muestras, la LDA calcula una matriz de dispersión entre clases de la siguiente manera (Duda et al., 2000):

$$S_b = \sum_{j=1}^c N_j (\mathbf{m}_j - \bar{\mathbf{m}})(\mathbf{m}_j - \bar{\mathbf{m}})^T \quad (2.31)$$

donde  $N_j$  corresponde al número total de muestras de la  $j$ -ésima clase  $C_j$ , teniendo en cuenta todas las clases  $\bar{\mathbf{m}}$  es la media de todas las muestras y  $\mathbf{m}_j$  es la media de la clase  $C_j$ . Además, la LDA también considera el cálculo de la matriz de dispersión dentro de las clases como:

$$S_w = \sum_{j=1}^c \sum_{i=1}^{N_j} (\mathbf{x}_i^j - \mathbf{m}_j)(\mathbf{x}_i^j - \mathbf{m}_j)^T = \sum_{j=1}^c S_{w_j} \quad (2.32)$$

donde  $\mathbf{x}_i^j$  es la  $i$ -ésima muestra que pertenece a la clase  $C_j$ , resultando en  $S_{w_j}$  la matriz de covarianza correspondiente de la clase  $C_j$ .

El vector óptimo de proyección  $\mathbf{W}_{LDA}$  que es elegido por la LDA permite obtener clases bien separadas ya que la matriz obtenida contiene columnas ortonormales que maximizan la relación del determinante de la matriz de entre clases de las muestras proyectadas del determinante de la matriz de dispersión de clase dentro de las muestras proyectadas:

$$\mathbf{W}_{LDA} = \arg \max \frac{|W^T S_b W|}{|W^T S_w W|} = [\mathbf{w}_1 \quad \mathbf{w}_2 \quad \cdots \quad \mathbf{w}_m] \quad (2.33)$$

donde  $\{\mathbf{w}_i | i = 1, 2, \dots, m\}$  pertenece al conjunto de vectores propios generalizados también conocidos como vectores discriminantes de la matriz  $S_b$  y  $S_w$  que corresponden a los valores propios generalizados de mayor relevancia de la clase  $C-I$   $\{\lambda_i | i = 1, 2, \dots, m\}$ .

De este modo, la extracción de indicadores que resulta en  $V$  se obtiene a través de la proyección del conjunto de datos original de indicadores  $X$  en el espacio de dimensión reducida  $W_{LDA}$  como sigue:

$$V = W_{LDA}^T X \quad (2.34)$$

- **Mapas de auto-organización**

Aunque la mayoría de técnicas de con enfoques lineales de reducción ofrecen un buen rendimiento en la reducción de la dimensionalidad de indicadores, es posible que exista un conjunto de datos que no pueda ser reducido mediante la combinación lineal de funciones. En este sentido, el desarrollo de e implementación de técnicas de reducción no lineales son la solución ante esta problemática, y de acuerdo con un criterio de error predefinido, estas técnicas no lineales de reducción trataran de mapear el espacio de un conjunto de datos original en un espacio de menor dimensión, preservando al mismo tiempo la estructura local del espacio.

Los mapas de auto-organización (SOM) es quizás la técnica de reducción de indicadores no lineal más conocida, el aspecto más importante de los mapas de auto-organización es que están basados en redes neuronales cuyo objetivo es preservar las propiedades topológicas de un espacio de entrada. El espacio de salida está predefinido como una malla regular, donde cada neurona de la malla del SOM representa una unidad de coincidencia, MU (Matching unit). Para cada neurona,  $n_i$ , se define un vector de peso  $d$ -dimensional  $w_{ni}$ . Los pesos representan las coordenadas de las neuronas en el espacio de entrada, es decir, el número de indicadores. Por lo tanto, la asignación se realiza asignando cada punto de datos de entrada,  $d_{in_j}$ , a una de estas neuronas, es decir, aquella cuyo vector de peso es el más cercano al punto, que es conocido como el vector más próximo (BMU-Best Matching Unit). El vector de posición de cada punto de datos en el espacio de salida,  $d_{out_j}$ , esta entonces dado por la posición de la malla de la BMU correspondiente. La función de error utilizada es la siguiente:

$$E_{SOM} = \sum_i \sum_{din_j \in n_i} (wn_i - dout_j)^2 \quad (2.35)$$

El  $E_{SOM}$  expresa la distancia media cuadrada de un punto de datos a su BMU representativa. La minimización del  $E_{SOM}$  representa el objetivo del entrenamiento, y se realiza con respecto a los vectores de peso  $wn_i$ . Para cada iteración,  $l$ , que representa al enfoque de descenso de gradiente, conduce a la regla de actualización basada en una tasa de aprendizaje,  $\alpha$ :

$$wn_i^{(l+1)} = wn_i^{(l)} - \alpha^{(l)} \left( \nabla E_{SOM}^{(l)} \right)_i \quad (2.36)$$

Durante el entrenamiento,  $\alpha(l)$  disminuye monótonicamente preservando la topología local de cada unidad de la neurona. Clásicamente, el rendimiento del SOM es evaluado por el error de cuantificación medio y error topográfico en términos de los datos de entrenamiento. El error de cuantificación medio significa la distancia media de cada vector de datos a su BMU, y el error topográfico significa el porcentaje de vectores de datos para los cuales la BMU y la segunda BMU no son unidades adyacentes.

Antes del entrenamiento del SOM, la red neuronal compuesta por el número predefinido de unidades de coincidencia se inicializa al azar dentro del espacio de datos de entrada, Figura 9a. Durante el entrenamiento, Figura 9a, la malla de MU se adapta sucesivamente a los pesos  $wn_i$  para preservar tanto como sea posible las topologías locales. Finalmente, la malla entrenada puede ser evaluada con datos nuevos, Figura 9c, donde se calcula la distancia euclídea a cada MU, y la MU más cercana se considera la BMU que se le asigna a la muestra evaluada. Mediante este procedimiento, los datos de entrada pueden ser, entonces, modelados por un pequeño número de MU. Además, durante el proceso de formación, cada MU puede asociarse a una etiqueta de clase siguiendo un procedimiento de votación por mayoría entre sus puntos de datos más cercanos. Así, se puede obtener el diagnóstico posterior (Kohonen, 2001).




Figura 9. Proceso de extracción de indicadores mediante SOM: (a) datos de entrada e inicialización aleatoria, (b) entrenamiento resultante, y (c) evaluación de un nuevo punto.

## 2.4 Algoritmos inteligentes de clasificación y optimización

Una parte importante dentro de los esquemas de condición de monitoreo y diagnóstico son las etapas en donde se realiza la identificación y clasificación de fallas evaluadas; normalmente es identificación y clasificación es realizada por algoritmos de clasificación, y se da a partir de la evaluación del conjunto de indicadores previamente obtenidos para la caracterización las condiciones de operación de la maquinaria.

En este sentido, los sistemas inteligentes son aquellos (elementos, objetos, instrumentos, etc.) que emulan un comportamiento similar a la inteligencia humana, algunas de las capacidades que pueden tener los algoritmos inteligentes son: reconocimiento de patrones, toma de decisiones, aprendizaje, razonamiento, entre otros. Dentro de los sistemas o algoritmos inteligentes más utilizados en tareas de clasificación y optimización están las redes neuronales, los sistemas de inferencia difusa, algoritmos inteligentes, entre otros (Duda, et al., 2000).

### 2.4.1 Redes neuronales

Una red neuronal artificial o comúnmente conocida como red neuronal es un método de procesamiento de información inspirado en sistemas biológicos, y representa quizás a uno de los modelos matemáticos más utilizados con un amplio rango de aplicaciones. Las redes neuronales, como su nombre lo indica, pretenden imitar en una pequeñísima escala la forma de funcionamiento del sistema nervioso central, específicamente las neuronas que forman el cerebro humano, las cuales son elementos individuales de procesamiento, estas neuronas pueden tener contacto con el ambiente por medio de los sentidos, pueden hacer

conexiones con ellas mismas, y también pueden actuar por medio de glándulas o impulsos nerviosos hacia el exterior. La información que viaja entre las neuronas, es modificada por las sinapsis, estas pueden ser excitadoras e inhibitoras, estas sinapsis dan el comportamiento de la red neuronal. Las redes neuronales artificiales son el resultado de la investigación del procesamiento en paralelo, aplicadas en sus inicios al reconocimiento de patrones alcanzado en la actualidad una infinidad de aplicaciones.

Las redes neuronales son modelos basados en el cerebro humano, por lo tanto, una adecuada elección de los elementos que componen este modelo ayudará a obtener una mejor aproximación del modelo original, McCulloch y Pitts fueron los primeros en proponer un modelo de una neurona artificial, en la Figura 10 se muestra el modelo de una red neuronal, y en su formulación correspondiente.

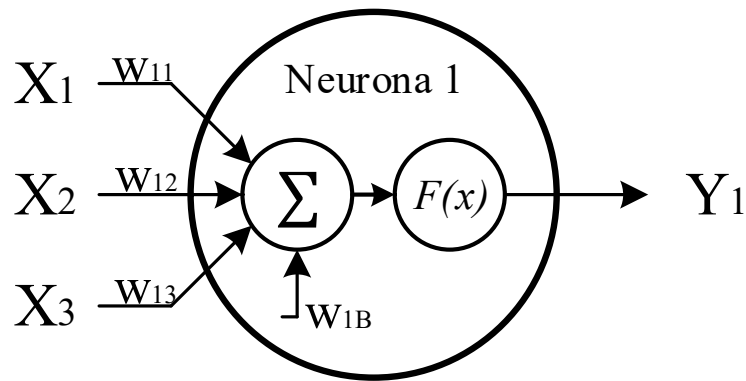


Figura 10. Composición básica de una NN.

$$y_1 = F(x_1w_{11} + x_2w_{12} + x_3w_{13} + w_{1B}) \quad (2.37)$$

Donde  $x_1$ ,  $x_2$  y  $x_3$  son las entradas,  $w_{11}$ ,  $w_{12}$ ,  $w_{13}$  y  $w_{1B}$  son los pesos o conexiones entre neuronas y  $F(x)$  es una función de activación, así para un número de entradas  $n$ , lo anterior puede expresarse como:

$$y_1 = F\left(\sum_{i=1}^n x_i w_{1i} + w_{1B}\right) \quad (2.38)$$

Esencialmente una red neuronal está constituida por tres elementos. En una unidad de proceso, se reciben las entradas del ambiente o de células vecinas, y se calcula su valor de salida para enviarlo a las neuronas vecinas o reenviarlas al ambiente. La conexión entre neuronas, une a las neuronas de una red neuronal, y en estas conexiones se tiene asociado un

peso en el cual está almacenado el aprendizaje. Las funciones de activación son reglas que combinan las entradas con los pesos de las conexiones, además, es necesario también que exista una regla para evaluar la entrada global de la neurona para determinar el estado en el que se encontrará la neurona para determinar un nuevo estado de activación (Theodoridis y Koutroumbas. 2006).

#### **2.4.2 Sistemas de inferencia difusa**

La lógica difusa es una variación más potente de la lógica tradicional donde no solo valores entre falso y verdadero son permitidos, sino que también conjunto compuestos con una cantidad mayor de valores sin fronteras bien definidas. La lógica difusa se desarrolló a partir de la teoría básica de los conjuntos difusos establecidos por Lofti Zadeh en 1965, donde cada conjunto difuso es un conjunto de elementos cuya pertinencia al mismo es gradual y no absoluta. Para cada conjunto difuso se define una función de pertenencia que indica la medida en que cada elemento forma parte de ese conjunto difuso. Un conjunto difuso  $A$  se define mediante notación matemática como  $A = \{(x, \mu_A(x))/x \in U\}$ , así mismo su función de pertenencia se denota entonces como  $\mu_A(x) \in [0,1]$ .

La lógica difusa representa una herramienta útil para las estrategias de condición de monitoreo y diagnóstico para la detección automática de fallas, la lógica difusa puede abordar sin problema y es muy útil cuando los límites o fronteras entre valores no están claramente definidos o existe eventos que están parcialmente traslapados. El concepto más importante en la lógica difusa es el de función de membrecía, las funciones de membrecía son funciones que definen como un elemento en el espacio de entrada será mapeado a un valor de la función de membrecía o a un grado de la función de membrecía entre 0 y 1. Las funciones de membrecía más usadas incluyen funciones triangulares, funciones trapezoidales, funciones Gaussianas y funciones campana.

La mayoría de sistemas difusos están basados utilizan tres etapas para hacer sus operaciones lógicas y generar un resultado. Primero, las entradas son convertidas en un conjunto de variables difusas por medio de un proceso de fusificación, donde por cada entrada se general de 3 a 9 variables difusas, y cada variable difusa tiene un valor entre cero y uno Después, la lógica difusa es aplicada a las variables difusas de entrada para generar un conjunto de variables difusas de salida a través de un conjunto de reglas difusas. Y finalmente, en la etapa de desfusificación se generan una o más variables analógicas de salida

a partir del conjunto de variables difusas de salida, estas variables generadas son usadas como las variables de control; y en el caso de esquemas de condición de monitoreo y diagnóstico estas variables servirán para definir la condición de operación de la maquinaria (Duda et al., 2000).

### **2.4.3 Algoritmos genéticos**

Para algunas aplicaciones, la selección de algunos parámetros resultar ser una tarea difícil, y si no se cuenta con la experiencia necesaria, este proceso se puede convertir en un proceso largo y tedioso. Para abordar este tipo de problemas ya existen algoritmos de optimización que pueden ser empleados, la idea general es que por medio de diferentes metodologías o técnicas sea posible configurar un algoritmo de optimización con la finalidad de encontrar los parámetros que maximicen o satisfagan una función objetivo.

Los AG fueron originalmente introducidos por Holland en 1975, y están basados en los principios de la genética natural y en la selección natural, filosóficamente en base a la teoría de Darwin de la “supervivencia del más apto” (Rao, 2009). Los AG difieren fuertemente en concepción de otros métodos de investigación, incluyendo los métodos tradicionales de optimización y otros métodos de investigación estocásticos, ya que mientras otros métodos siempre procesan puntos simples, los AG mantiene una población de soluciones potenciales (población de individuos). Los individuos son representados por cromosomas compuestos de genes. Los AG operan en los cromosomas, lo cual representa las propiedades hereditarias de los individuos. Por analogía con la naturaleza, a través de la selección de individuos aptos, soluciones potenciales al problema de optimización viven para reproducir, y los individuos débiles tienden a desaparecer. Nuevos individuos son creados de uno o dos padres por cruce y mutación respectivamente reemplazando a viejos individuos en la población (Rao, 2009).

### **2.5 Cálculo de indicadores de confiabilidad**

La confiabilidad puede ser definida como una medida de la consistencia de los resultados de una prueba de medidas cuantitativas, donde teóricamente, cada una de las pruebas contiene algún error que es una porción de los valores de la prueba que no es relevante para la construcción que se espera medir. Desde un punto de vista de productividad, la confiabilidad también puede definirse como una medida de la capacidad de un producto o

parte para realizar su función prevista en un conjunto de condiciones prescritas; y por lo tanto, la confiabilidad es una probabilidad. Considerando que un producto generado durante un proceso específico tiene una confiabilidad de 0.90, significa que tiene una probabilidad del 90% de funcionar según lo previsto; la probabilidad de que falle, es decir, su índice de fallas, es  $(1.0 - .90) = 0.10$  o 10%. De esto se espera que, en promedio, 1 de cada 10 de los productos generados fallarán o, de manera equivalente, que el proceso de producción fallara en promedio 1 vez cada 10 intentos. Por lo tanto, si se tiene un proceso de producción con confiabilidad de 0.985, implicaría que, de cada 1000 que se genera el producto, se tendrán en promedio 15 productos con falla.

La confiabilidad es un factor importante de la calidad del producto o proceso, obtener niveles de confiabilidad altos se ha convertido en un reto importante y para lograrlo se pueden utilizar diferentes estrategias que mejoren el rendimiento de los procesos. Por ejemplo, la confiabilidad de un producto específico se puede determinar a partir de la confiabilidad de sus partes; en este sentido, la confiabilidad promedio de una pieza se puede medir probando varias unidades del mismo tipo a lo largo del tiempo hasta que algunas o todas fallen. Existen diversos procedimientos para calcular la confiabilidad de un instrumento, producto, proceso, etc., y la mayoría de los procedimientos obtienen la confiabilidad mediante el cálculo de un coeficiente; los coeficientes de confiabilidad y métodos más utilizados son: el coeficiente test-retest, método de división por mitades, método de Kuder-Richardson y coeficiente alfa de Cronbach (IBM SPSS Statistics, Bruton et al., 1999).

Sin embargo, el coeficiente de confiabilidad alfa de Cronbach es una de las medidas de confiabilidad más utilizadas en diferentes áreas (Cronbach, 1951). La confiabilidad alfa de Cronbach describe la confiabilidad de una suma (o promedio) de mediciones  $k$  donde las medidas  $k$  pueden representar  $k$  calificadores, ocasiones, formas alternativas o elementos de cuestionarios/pruebas. Cuando las medidas representan múltiples elementos de cuestionarios o prueba, que es la aplicación más común, el alfa de Cronbach se conoce como una medida de confiabilidad de "consistencia interna". El coeficiente de alfa de Cronbach mide el grado en que las respuestas de los elementos obtenidos al mismo tiempo se correlacionan mucho entre sí, y se ha considerado como punto de corte ampliamente aceptado por la gran mayoría de las ciencias sociales y diferentes áreas de aplicación el valor de alfa de 0.70; por lo tanto,



valores superiores a 0.70 representan una excelente confiabilidad. El coeficiente de alfa de Cronbach se define como:

$$\alpha = \frac{k}{k-1} \left( 1 - \frac{\sum \sigma_i^2}{\sigma_t^2} \right) \quad (2.39)$$

donde,  $\alpha$  es la confiabilidad estimada para un conjunto completo de muestras de una prueba,  $k$  es el número de muestras,  $\sigma_t^2$  es la varianza de todas las muestras de la prueba (el cuadrado de la desviación estándar), y  $\sum \sigma_i^2$  es la suma de las varianzas para la muestra  $k$ .

# Capítulo III

## 3. Metodologías de diagnóstico

En este capítulo se presenta el proceso de desarrollo de este trabajo que se centra en la propuesta de una metodología de condición de monitoreo y diagnóstico de múltiples fallas en una cadena cinemática; por lo tanto, en este capítulo se realizará la descripción detallada de la metodología que se propuso para determinar la condición de estado de una cadena cinemática. En la Figura 11 se muestra el diagrama a bloques de la metodología que se siguió para determinar la condición de estado de la cadena cinemática; primero se realizó la instrumentación de la cadena cinemática para medir diferentes magnitudes físicas (vibración, corriente y temperatura); después, bajo diferentes frecuencias de operación se evaluaron experimentalmente cuatro condiciones en la caja de engranes y seis condiciones en el motor de inducción, y para cada una de las condiciones evaluadas se hizo la adquisición de las diferentes magnitudes físicas. Una vez realizada la experimentación, se implementaron las etapas de *Procesamiento de señales*, *Fusión de datos* y *Diagnóstico* consideradas en el diagrama del planteamiento general; y así, primero se hizo un análisis de los efectos generados por la combinación de fallas en la caja de engranes y el motor de inducción, enseguida se hizo la identificación y clasificación de las diferentes severidades de desgaste uniforme en los engranes, y finalmente se hizo la identificación y clasificación de las diferentes condiciones de falla del motor de inducción.

Respecto al desarrollo de esta metodología, ésta fue implementada en MATLAB® que es un software con un campo de aplicaciones bastante amplio, en específico este software fue utilizado por tener una gran cantidad de herramientas que facilitan la utilización de técnicas dedicadas al procesamiento de señales, y también facilitan la implementación de los algoritmos inteligentes.

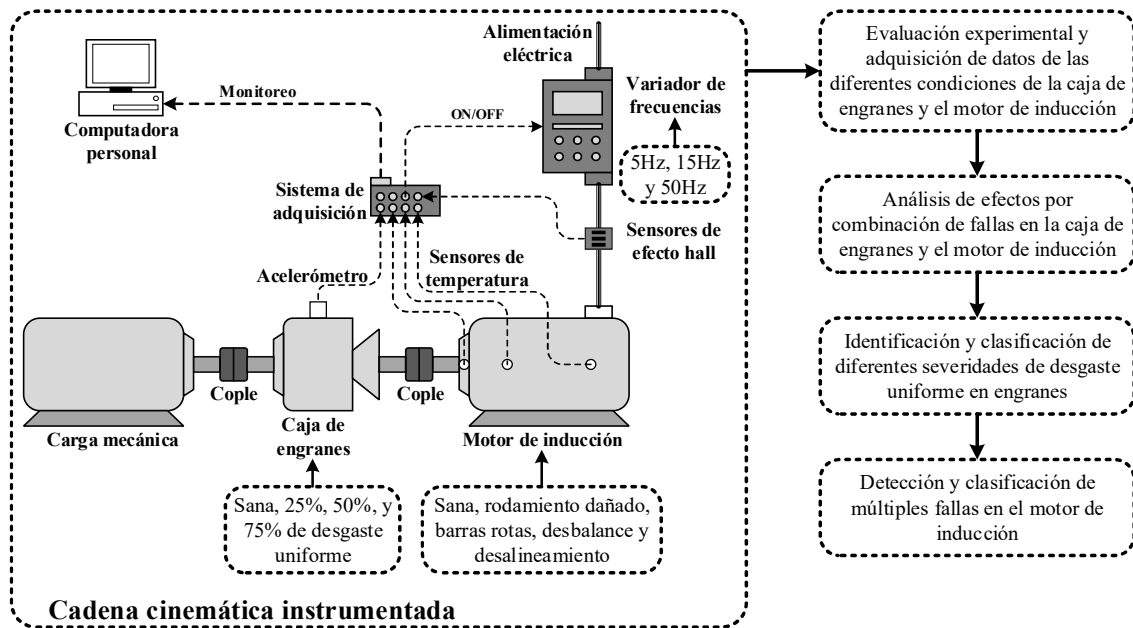


Figura 11. Diagrama general de la metodología desarrollada para la cinemática y su instrumentación

### 3.1 Instrumentación de la cadena cinemática

El banco de pruebas experimental utilizado para validar la metodología de diagnóstico propuesta se basa en una cadena cinemática, donde esta cadena cinemática está compuesta principalmente por un motor de inducción, una caja de engranes y un generador de corriente continua; asimismo, se hizo la instrumentación con diferentes sensores para poder realizar la medición de diferentes magnitudes físicas (vibraciones, corrientes, temperaturas y velocidad de giro), en la anterior Figura 11 se muestra un diagrama a bloques de los elementos que forman la cadena cinemática, su interconexión y el cableado de la instrumentación utilizada. Específicamente, el motor de inducción es un motor de inducción trifásico de 1492 W (modelo WEG00236ET3E145T-W22), y para alimentar y controlar su velocidad de rotación se utiliza un controlador de frecuencia variable (modelo WEGCFW08). A continuación, el motor de inducción es acoplado a la caja reductora de engranes de relación 4:1 (modelo BALDOR GCF4X01AA) para impulsar su eje de entrada; posteriormente, y a su vez, el eje de salida de la caja de engranes impulsa el generador de corriente continua (modelo BALDOR-CDP3604) que se utiliza como carga mecánica.

En este trabajo se propuso medir diferentes magnitudes físicas, en este sentido, se instaló un acelerómetro triaxial (modelo LIS3L02AS4) en la parte superior de la caja de

cambios para medir la aparición de vibraciones en los plano perpendicular y tangencial al eje de rotación de la caja de engranes. Las señales de corriente del estator del motor de inducción fueron adquiridas utilizando tres sensores de corriente de efecto Hall (modelo L08P050D15) de Tamura Corporation, estos sensores de efecto Hall fueron instalados en los cables de alimentación que están entre el variador de frecuencias y el motor de inducción. Además, la temperatura de algunas partes del motor de inducción también fueron medidas mediante tres RTD's (modelo DM-301) de Labfancility LTD, los RTD se colocaron en diferentes lugares del motor de inducción, uno de ellos está cerca del área del rodamiento en el parte frontal del motor de inducción, los otros dos RTD's están justo en la zona del rotor en uno de los lados laterales del motor de inducción. Los sensores instalados, el acelerómetro, los sensores de efecto Hall y los RTDs fueron montados individualmente en tarjetas con su correspondiente acondicionamiento de señal y sus respectivos filtros anti-alias.

Para realizar la adquisición de datos, se utilizó en una tarjeta de adquisición de datos (DAS) un convertidor analógico-digital (modelo ADS7841) de 12 bits de 4 canales de salida en serie de Texas Instruments Incorporated. La tarjeta DAS es un diseño propio de bajo costo basado en tecnología de arreglo de compuertas programables de campo (FPGA-Fiel Programable Gate Array). Las frecuencias de muestreo que se utilizaron durante la adquisición de las vibraciones, corrientes del estator, temperaturas y velocidad de giro se fijó en 3 kHz, 4 kHz, 1 kHz y 4 kHz respectivamente, la tarjeta DAS fue programada para adquirir estas señales durante el régimen permanente cuando el motor de inducción está bajo condición de operación. Además, con el objetivo de automatizar las pruebas durante la experimentación, la tarjeta DAS también controlo un relevador que conmuta el estado ON / OFF del variador de frecuencias; después de realizar las diferentes pruebas experimentales, toda la información adquirida por la tarjeta DAS fue enviada y almacenada en una computadora personal (PC) para el análisis offline. En la Figura 12 se muestra una imagen del banco de pruebas experimental en el que se evaluaron diferentes condiciones de operación, en esta misma figura se muestra la tarjeta DAS utilizada y la instrumentación ejecutada.




Figura 12. Banco de pruebas experimentales basado en una cadena cinemática

### 3.1.1 Fallas evaluadas en el motor de inducción

Como se ha mencionado, este trabajo está centrado en evaluar experimentalmente en el motor de inducción, así, las condiciones evaluadas son: estado sano (Healthy-HLT), rodamiento dañado (Bearing defect-BD), barras rotas (Broken rotor bar-BRB), desbalance (Unbalance-UNB) y desalineamiento (Misalignment-MAL). Las fallas de BD y BRB se reprodujeron induciendo un daño artificial en estos elementos (rodamiento y rotores del motor de inducción), mientras que las fallas de UNB y MAL se generaron al modificar la configuración mecánica de la cadena cinemática donde el motor de inducción esta interconectado.

Concretamente, el motor de inducción utiliza un rodamiento modelo 6205-2ZNR en la parte frontal del eje de su rotor, por lo que se utilizó un rodamiento de las mismas características para maquinar un orificio que atravesara todo el espesor de su pista exterior, este orificio fue maquinado con un cortador de tungsteno cuyo diámetro es de 1.191 mm. Las fallas de BRB fueron generadas en dos severidades al maquinado un barreno de 6 mm de diámetro sobre una de las barras de dos rotores similares a el que utiliza el motor de inducción; por lo tanto, en el rotor que representará la falla de media barra rota (1/2 BRB) se

maquinó un barrenó con una profundidad de 3 mm que corresponde aproximadamente al 22% de la sección transversal de la barra del rotor, y en el otro rotor que representa la falla de una barra rota (1 BRB) se maquinó el barrenó con una profundidad de 14 mm que perforó completamente la sección transversal de una de las barra del rotor.

Por otra parte, la condición de UNB en máquinas rotatorias se presenta cuando existe una distribución de carga no uniforme que genera que el centro de masa este fuera del eje rotación; a este respecto, se fijó un tornillo en uno de los acoplamientos mecánicos del motor de inducción para reproducir la condición UNB. La condición MAL aparece cuando las líneas centrales de un par de ejes acoplados que no coinciden entre sí; como resultado, se produce un aumento de la carga dinámica en rodamientos y acoplamientos mecánicos debido a la desalineación angular entre ejes. De este modo, la condición MAL se generó mediante el desplazamiento de extremo libre del motor de inducción, este extremo fue desplazado 5 mm sobre el plano horizontal. En la Figura 13 se muestra el conjunto de fallas que fueron producidas artificialmente y probadas en el banco de pruebas experimentales.

La mayoría de las condiciones consideradas se evaluaron experimentalmente al reemplazar los elementos con daño artificial por los elementos sanos del motor de inducción, únicamente las condiciones de UNB y MAL fueron inducidas al modificar el centro de masa del motor de inducción y al mover el extremo libre del mismo. Además, durante la experimentación el motor de inducción fue operado bajo diferentes frecuencias de funcionamiento; por lo tanto, las frecuencias de operación de 5 Hz, 15 Hz y 50 Hz que fueron establecidas en el variador de frecuencias produjeron una velocidad de rotación promedio de 294 rpm, 890 rpm y 2985 rpm respectivamente en el motor de inducción.




Figura 13. Conjunto de fallas evaluadas en el motor de inducción. (a) Rodamiento dañado. (b)  $\frac{1}{2}$  barra rota. (c) 1 barra rota. (d) Desbalance. (e) Desalineamiento.

### 3.1.2 Fallas evaluadas en la caja de engranes

Las cajas de engranes son otro de los elementos principales de maquinaria basada en cadenas cinemáticas, por eso, en este trabajo se consideró evaluar diferentes condiciones en la caja de engranes: estado sano (Healthy-HLT), 25%, 50% y 75% de desgaste uniforme, respectivamente.

Respecto a estas condiciones consideradas, para la reproducción del desgaste uniforme se maquinaron tres engranes con dimensiones similares a las de uno de los engranes que utiliza la caja de engranes; estos engranes fueron maquinados y artificialmente dañados en una fábrica especializada. Por lo tanto, considerando que se tiene un conjunto de engranajes en una condición sana, éstos fueron sometidos a un proceso de mecanizado donde todos sus dientes fueron desgastados por un cortador del tungsteno; después de este proceso de desgaste, dichos engranajes también fueron sometidos a un proceso de lapeado con el fin de hacer lo más real posible el desgaste inducido en los engranes.

La caja de engranes instalada en la cadena cinemática consta de dos engranajes, uno de ellos es el engranaje conductor y el otro es el engranaje conducido, y cada uno de estos engranajes tiene 18 y 72 dientes, respectivamente. Los engranes maquinados que fueron utilizados para la evaluación de la condición de la caja de engranes se muestran en la Figura 14a a la Figura 14d: HLT, 25%, 50% y 75% de desgaste uniforme, respectivamente. Para evaluar experimentalmente cada una de estas condiciones se reemplazó alternativamente el engrane sano por cada uno de los engranes con diferente grado de desgaste.




Figura 14. Conjunto de engranes maquinados: (a) Sano, (b) 25 %, (c) 50 % y (d) 75 % de desgaste uniforme, respectivamente.

### 3.2 Análisis de los efectos generados por la combinación de fallas de la caja de engranes y el motor de inducción

Una primera parte para la identificación de fallas en la cadena cinemática conto de un análisis de los efectos generados por la combinación de fallas de la caja de engranes y del motor de inducción, las fallas analizadas son las de BD combinadas con las diferentes condiciones de la caja de engranes (HLT, 25%, 50% y 75% de desgaste), en la Figura 15 se muestra e diagrama bloques que se propuso para realizar el análisis .

En primer lugar, en la etapa de *Condiciones evaluadas en la cadena cinemática* se definieron los casos de estudio como: estado sano, tres niveles de desgaste uniforme en engranes, rodamiento dañado y la combinación de rodamiento dañado con las diferentes severidades de engrane desgastado. Como anteriormente se mencionó, estas fallas fueron reproducidas artificialmente y los elementos dañados fueron reemplazan en una cadena cinemática para realizar diferentes experimentos. Además, se utilizan diferentes frecuencias de operación en el motor de inducción para observar los efectos de la velocidad de rotación en cada uno de las condiciones estudiadas.

Posteriormente esta la etapa de *Adquisición de datos*, donde de cada una de las experimentaciones que se realizó se monitorearon y adquirieron los datos de las señales de vibración del acelerómetro triaxial que se colocó en la parte superior de la caja de engranes.



Además, la corriente de estator del motor de inducción y su velocidad de rotación se obtuvo de los sensores de efecto Hall y de un encoder digital, respectivamente. Durante la adquisición de datos se hizo el monitoreo y adquisición de las diferentes señales cuando el motor de inducción de la cadena cinemática se encontraba bajo el régimen estable de operación.

A continuación, en la tercera etapa de *Cálculo de indicadores*, se les aplicó una ventana de tiempo Hanning a las señales de vibración y de corriente para reducir la filtración espectral, y sobre estas señales pre-procesadas se calculó su respectivo espectro de frecuencias para lo cual se empleó la transformada rápida de Fourier (FFT-Fast Fourier Transform) para las señales de vibración y para las señales de corriente se calculó densidad espectral de potencia (PSD-Power Spectral Density). Adicional a esto, se realizó el cálculo de las frecuencias características de falla para los diferentes elementos estudiados (rodamiento y engranes), estas componentes de frecuencia se calcularon a partir de la velocidad de rotación que se obtuvo para las diferentes condiciones evaluadas.

Después, en la etapa de *Análisis espectral*, sobre los espectros calculados de vibraciones y de corriente se hizo la localización de aquellas componentes características de frecuencia que se estimaron para el rodamiento y los engranes, la localización de estas componentes se realizó para analizar el comportamiento que genera la aparición de estas fallas en una región espectral específica. Finalmente, en la etapa de *Diagnóstico*, se evaluó la condición de la cadena cinemática, esta respuesta se generó de comparar el incremento en amplitud y demodulación que se surgió sobre las componentes características de falla calculadas y localizadas en las diferentes regiones de los espectros.

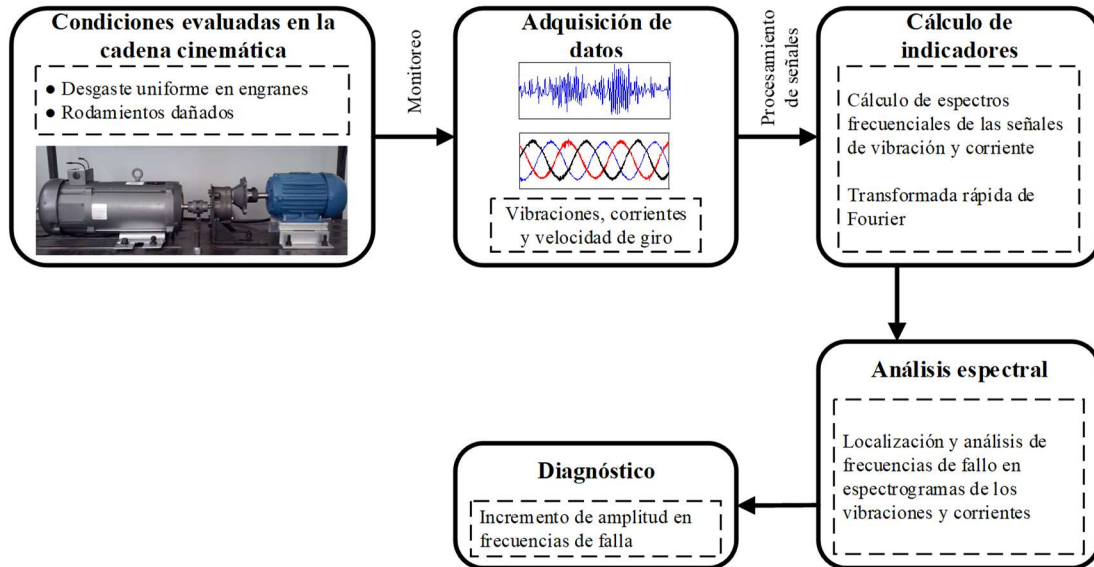


Figura 15. Diagrama bloques para efectuar el análisis de los efectos generados por combinar fallas de la caja de engranes y el motor de inducción.

### 3.3 Identificación y clasificación de las diferentes severidades de desgaste uniforme en engranes

En una segunda parte de la identificación de fallas de la cadena cinemática se propuso analizar las diferentes severidades de desgaste uniforme evaluadas en la caja de engranes, en la Figura 16 se muestra el diagrama bloques que se utilizó para identificar y clasificar las diferentes severidades del desgaste en la caja de engranes bajo diferentes frecuencias de operación.

Para esta identificación se parte de que se evaluarán cuatro condiciones de estado en el *Sistema de transmisión de engranes* de la cadena cinemática, entre estas condiciones se evaluó una condición sana, y tres severidades de desgaste uniforme, 25%, 50% y 75% de desgaste. Después en la etapa de *Adquisición de datos*, para cada una de las condiciones evaluadas se monitorearon y adquirieron continuamente las vibraciones que se generaron en el plano perpendicular al eje de rotación de la caja de engranes.

Posteriormente, en la etapa de *Cálculo de indicadores*, se realizó una caracterización de cada una de las señales de vibraciones adquiridas estimando un conjunto de 15 indicadores estadísticos de cada una de ellas. Este conjunto de indicadores estadísticos que se propuso está compuesto por: la media, valor máximo, RMS, media de la raíz cuadrada, desviación estándar, varianza, factor de forma RMS, factor de forma de raíz cuadrada, factor

de cresta, factor de impulso, skewness, kurtosis y quinto y sexto momentos normalizados. Además, como anteriormente ya se mencionó este conjunto de indicadores estadísticos tiene la capacidad de analizar las tendencias de las señales con una fuente de información de alto rendimiento, tanto así que ya se han obtenido muy buenos resultados al incluir indicadores de este conjunto propuesto en estrategias de condición de monitoreo para la identificación de fallas en sistemas electromecánicos (Igba et al., 2016).

La cuarta etapa es la *Selección de indicadores*, en donde analizó por separado las capacidades discriminativas de los indicadores estadísticos estimados que pertenecen a los diferentes pares de condiciones sano-fallo, esto se realizó con el objetivo de preservar y filtrar los indicadores con alta capacidad discriminativa que mejor describan la condición de trabajo de la caja de engranes. Para este proceso de selección de indicadores se propuso evaluar a cada uno de los indicadores mediante el cálculo de su coeficiente de Fisher; y que en esta estrategia se consideró como un análisis de Fisher basado en la fuerza bruta, en el que se obtiene la relación entre la estimación de dispersión dentro de la clase y la estimación de dispersión entre clases, aquí debe mencionarse que cuando se habla de clase es para hacer referencia a una de las condiciones consideradas. Específicamente, este coeficiente de Fisher calculado puede interpretarse como una medida relativa que representa la distancia entre las diferentes clases y la dispersión entre los puntos de datos pertenecientes a cada clase. Entonces, un conjunto de indicadores que producen un coeficiente de Fisher pequeño implica tener capacidades discriminativas pobres, mientras que un coeficiente de Fisher alto implica tener mejores capacidades discriminativas. En este sentido, se propuso que los indicadores fueran seleccionados de acuerdo a la relevancia de sus capacidades discriminativas, es decir, aquellos indicadores con coeficientes de Fisher significativamente grandes fueron considerados como los indicadores con mayores capacidades discriminativas de falla, mientras que aquellos indicadores con coeficientes de Fisher inferiores fueron considerados como indicadores no discriminatorios sin información relacionada con la condición de falla evaluada. Esta estrategia de selección de indicadores está basada en un problema combinatorio, y por lo tanto se calculó los coeficientes de Fisher para todas las combinaciones de indicadores estadísticos disponibles de subconjuntos compuestos por uno, dos y tres indicadores estadísticos. Para eliminar todos aquellos indicadores de poca utilidad, durante el proceso de selección de indicadores se analizó las capacidades discriminativas de

los subconjuntos de indicadores estadísticos considerando todos los pares de condiciones sanas-fallo. Luego, después de que se evaluó el coeficiente de Fisher para cada uno de los indicadores estadísticos, el subconjunto de indicadores estadísticos con el mejor coeficiente de Fisher fue el que se consideró como el subconjunto de indicadores más relevante y discriminatorio que proporciona una mejor descripción para distinguir entre cada uno de los pares correspondientes de condición sana-fallo evaluados.

En la quinta etapa, *Extracción de indicadores*, todos los subconjuntos de indicadores seleccionados como los más discriminativos para cada pareja de condiciones sano-fallo fueron sometidos a una transformación de base y un proceso de compresión por medio de la técnica de reducción LDA. Como resultado de este proceso, se extrajo un nuevo conjunto de indicadores compuesto por la combinación en diferentes ponderaciones de los indicadores estadísticos previamente seleccionados. En consecuencia, debido a la transformación de base que se realizó, fue posible proyectar el nuevo conjunto de características extraídas en un espacio bidimensional que permitió obtener una interpretación visual de las diferentes condiciones consideradas. Además, la representación resultante de los indicadores extraídos en un espacio bidimensional facilitó la tarea de clasificación y diagnóstico fallas. Así, los indicadores estadísticos más discriminatorios seleccionados en la etapa anterior se proyectaron en una nueva base de espacio dimensional menor preservando sus capacidades discriminativas de diferenciación entre las condiciones consideradas.

Finalmente, la clasificación y el diagnóstico de las fallas se realizó en la sexta etapa Clasificación, y en esta etapa se evaluó el conjunto de indicadores extraídos para obtener el diagnóstico de la condición de operación de la caja de engranes. En este sentido, debe resaltarse que, en esta estrategia de diagnóstico que se propuso, se consideró un procesamiento de análisis consecutivo para los conjuntos iniciales de indicadores (*Selección de indicadores* y *Extracción de indicadores*); y mediante su implementación se eliminaron aquellos indicadores que no iban a ser capaces de representar en forma significativa los patrones característicos de las condiciones de trabajo de la caja de engranes. Por lo tanto, debido a que el número de indicadores se redujo a dos, y que además se enfatizaron los diferentes patrones de condición, fue posible utilizar una estructura de clasificación simple. Al respecto, se propuso usar un clasificador basado en inferencia difusa (Fuzzy based inference based classifier) para realizar el diagnóstico y clasificación de las condiciones

consideradas. Específicamente, en un sistema clásico de inferencia difusa hay un antecedente que es la entrada, y dicha entrada es evaluada por medio de funciones de pertenencia con el propósito de determinar su grado de asociación a un evento difuso específico. En el clasificador propuesto, el conjunto extraído de indicadores fueron las variables de entrada que se evaluaron en las funciones de pertenencia. A continuación, internamente el clasificador generó una conclusión al obtener el resultado o salida del sistema de inferencias difusas, estas inferencias difusas generalmente son una serie de operaciones lógicas también se conocen como reglas difusas. Además, el clasificador propuesto contó con cuatro salidas que representaron a cada una de las condiciones consideradas, el consecuente de cada función de pertenencia en el sistema de inferencia difusas quedó determinado por la función de pertenencia tipo Sugeno.

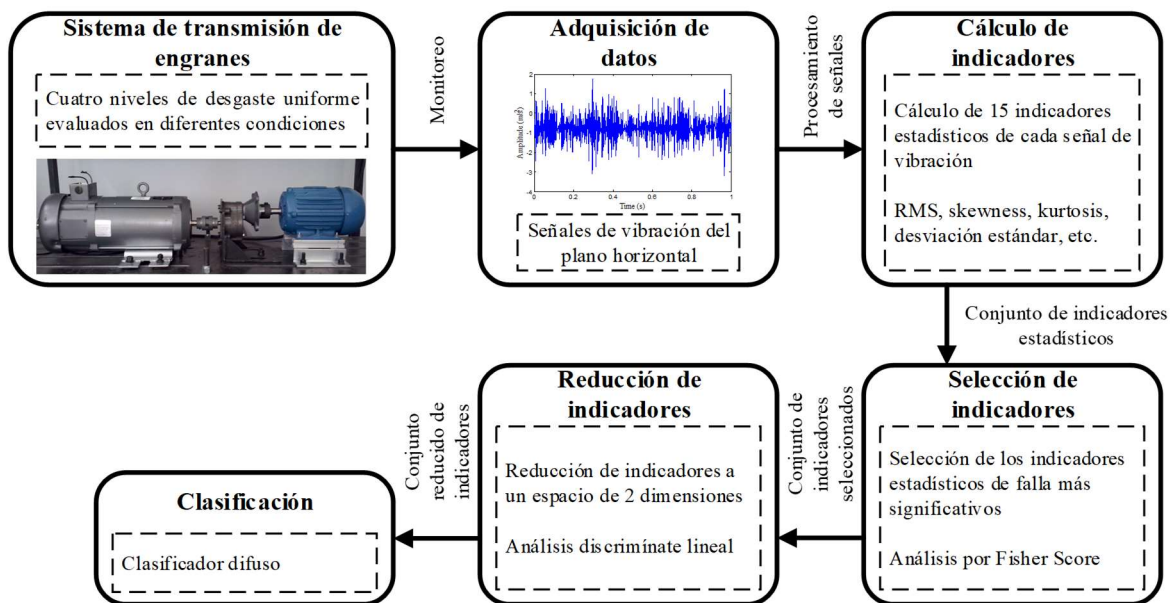


Figura 16. Diagrama bloques empleado para el monitoreo y diagnóstico del desgaste de engranes en diferentes condiciones de operación.

### 3.4 Detección y clasificación de múltiples fallas en el motor de inducción

La tercera parte de la identificación de fallas en la cadena cinemática se centró en el análisis de múltiples fallas sobre el motor de inducción, en la Figura 17 se muestra el diagrama bloques que se utilizó para la identificación de las múltiples condiciones de falla del motor de inducción.

En primer lugar, se realizó la definición de los casos de estudio en la etapa de *Condiciones evaluadas en la cadena cinemática*, y las diferentes condiciones evaluadas en el motor de inducción fueron: condición sana (HLT), rodamiento dañado (BD), media barra rota del rotor (1/2 BRB), una barra rota del rotor (1 BRB), desbalance (UNB) y desalineamiento (MAL). Durante la experimentación se hizo la adquisición de noventa mediciones de las vibraciones generadas por cada una de las condiciones consideradas, donde cada una de estas mediciones corresponde a un segundo de monitoreo constante del funcionamiento en régimen estable del motor de inducción, así para cada una de las condiciones evaluadas se obtuvo un patrón característico de vibraciones.

### **3.4.1 Descomposición de señales de vibración y cálculo de indicadores**

El procesamiento de señales es una parte esencial de las estrategias de condición de monitoreo y diagnóstico, específicamente para la identificación de múltiples fallas en el motor de inducción se realizó un procesamiento de señales más complejo. Por lo que las señales de vibración adquiridas fueron sometidas a un proceso de composición que se realizó por medio de la descomposición de modos empíricos (EMD); dicha descomposición fue se aplicó a las señales de cada una de las condiciones consideradas, el resultado de esta descomposición es un conjunto de modos intrínsecos (Intrinsic mode function- IMF) que se adaptan automáticamente al patrón vibratorio correspondiente.

Después, cada conjunto resultante de IMF's fue caracterizado mediante la estimación de 15 indicadores estadísticas basados en el tiempo, los indicadores estadísticos calculados son: media, valor máximo, RMS, media de la raíz cuadrada, desviación estándar, varianza, factor de forma RMS, factor de forma de raíz cuadrada, factor de cresta, factor de impulso, skewness, kurtosis y quinto y sexto momentos normalizados. Por lo tanto, se calculó un número de 150 indicadores numéricos para cada una de las condiciones consideradas. Este conjunto propuesto de indicadores es el mismo que se muestra en la Tabla 2.1, y estos indicadores estadístico basados en el tiempo han sido utilizado exitosamente en la detección de fallos en el motor eléctricos debido a su información de alto rendimiento y sus capacidades para analizar las tendencias generales de las señales (Delgado-Prieto et al., 2013).

### 3.4.2 Reducción de dimensionalidad de indicadores en múltiples etapas

Los conjuntos de indicadores estimados previamente para cada una de las condiciones consideradas son denominados conjuntos de alta dimensión, y estos conjuntos contienen una gran parte de la información relacionada con la condición de trabajo de la cadena cinemática, pero de estos indicadores sólo algunos contendrán la información más representativa para la diferenciación entre distintas condiciones de operación.

Por lo tanto, teniendo en cuenta que el conjunto de IMF's obtenido contiene información correlacionada, en una primera etapa de *Optimización de indicadores* se utilizó un algoritmo genético (GA-Genetic algorithm) en conjunto con la técnica de análisis de componentes principales (PCA-Principal Component Analysis) con la finalidad de encontrar aquel subconjunto de IMF que proporcione la mejor representación de cada una de las condiciones consideradas. Esta optimización de indicadores se realizó individualmente para cada condición considerada de la siguiente manera: un vector lógico con diez elementos representó los cromosomas del GA, en el que cada elemento representó a cada una de las IMF's obtenidas. Entonces, una población inicial se generó aleatoriamente considerando que al menos uno de los elementos contenidos en el vector lógico tiene que ser seleccionado para ser evaluado; y también se pueden evaluar a más de un elemento a la vez. Una vez definida la población inicial, se evalúa la función objetivo, que se basó en la acumulación de la varianza de los datos. A continuación, la IMF o IMF's a evaluar están ahora representadas por su conjunto de indicadores estadístico correspondiente; en este sentido, la varianza acumulada de las IMF's seleccionadas se calculó a través de PCA, y la función objetivo evaluó la varianza que fue acumulada por las primeras dos y tres componentes principales. Posteriormente, se generó otra población utilizando el método de selección de rueda de ruleta (Roulette), además de que el GA aplica una mutación y, basándose en la distribución gaussiana, se elige la nueva población, y luego se repite iterativamente hasta encontrar el conjunto de IMF's que presente la mejor acumulación de la variabilidad de datos; los criterios considerados para detener el proceso de optimización del algoritmo son controlados por diferentes objetivos como lograr una maximización de la varianza o alcanzar un número máximo de generaciones. En este proceso, cada condición de falla se evaluó con respecto de la condición sana; como resultado, los conjuntos de IMF's se optimizaron eliminando la

información redundante, y sólo la información discriminativa relacionada con cada condición se conservó en las IMF's selectas.

En una segunda etapa se hizo una *Selección de indicadores*, y en esta etapa de selección, se realizó un análisis de las capacidades discriminativas individuales de cada uno de los indicadores estadístico con el objetivo de filtrar y preservar los indicadores con mayor capacidad discriminativa. En este proceso, fueron considerados aquellos indicadores estadísticos que pertenecen al conjunto optimizado de IMF's. En este sentido, la selección de indicadores se realizó calculando el coeficiente de Fisher que es una medida relativa en términos de la distancia que hay entre puntos de datos en diferentes clases, esto significa que indicadores estadísticos con coeficiente de Fisher representan grandes distancias, mientras que aquellos indicadores con coeficientes de Fisher bajos representan distancias más pequeñas. En consecuencia, los indicadores son clasificados en función de su relevancia, es decir, los indicadores que obtienen mejores puntuaciones se consideran como los mejores con excelentes capacidades discriminativas. El método de selección de indicadores se generó mediante un problema combinatorio; en este sentido, el coeficiente de Fisher se calculó combinando todos los indicadores estadísticos, para esta combinación fueron considerados subconjuntos de dos y tres indicadores. Y así como en la etapa de optimización, en este proceso de selección se evaluaron las condiciones de falla respecto de la condición sana. Después de obtener el coeficiente de Fisher para cada uno de los indicadores, los tres primeros con el mejor puntaje en términos del coeficiente de Fisher fueron considerados como el conjunto de indicadores más significativo que mejor describe las condiciones de trabajo de la máquina.

Estas dos primeras etapas (*Optimización de indicadores y Selección de indicadores*) corresponden a un proceso de filtrado del conjunto inicial de indicadores alta dimensionalidad. Por lo tanto, para cada condición de falla considerada se obtuvo un conjunto de indicadores que contienen la información más significativa y discriminativa de cada una de las condiciones de funcionamiento de la cadena cinemática.

Finalmente, en una etapa de *Extracción de indicadores*, todos los conjuntos de indicadores seleccionados fueron sometidos a un proceso de compresión y a una transformación de base por medio de la técnica LDA. Con este proceso de compresión se extrajo un nuevo conjunto de indicadores, y estos indicadores extraídos son el resultado de



una combinación de diferentes pesos de los conjuntos de indicadores seleccionado. Además, estos indicadores extraídos ofrecen la ventaja de poder ser proyectados en un espacio bidimensional que permite una interpretación visual de las condiciones consideradas. Asimismo, esta representación bidimensional resultante facilitó la tarea de clasificación para el algoritmo de clasificación usado, ya que sólo se deben gestionar dos entradas. Con este enfoque de reducción de la dimensionalidad de indicadores, los indicadores con mejor capacidad discriminativa fueron proyectados en un espacio de dimensión reducida donde fueron conservadas y maximizadas sus capacidades para la discriminación entre las diferentes condiciones consideradas.

### **3.4.3 Clasificación**

En esta estrategia de diagnóstico propuesta para identificar múltiples fallas en el motor de inducción está basada principalmente en el procesamiento consecutivo del conjunto original de indicadores, por lo que a lo largo de este proceso se conservaron aquellos indicadores que son significativamente más importantes para representar los patrones característicos de cada una de las fallas. Por lo tanto, mediante la aplicación de esta estrategia de reducción de indicadores híbrida se obtuvo un alto rendimiento que permitió usar una configuración más sencilla en la estructura del clasificador.

En este sentido, se utilizó una estructura simple de un clasificador basado en redes neuronales (NN-Neural Network) para generar el diagnóstico de las condiciones consideradas. El clasificador que se utilizó tiene una estructura clásica de tres capas. La capa de entrada se compuso por dos neuronas que corresponden a los vectores de indicadores bidimensionales que se obtuvieron con la estrategia híbrida de reducción de indicadores propuesta. En la capa oculta se utilizaron diez neuronas de acuerdo con las recomendaciones clásicas de aplicación (Duda et al., 2000). La capa de salida se compuso por seis neuronas, una para cada condición considerada. Esta simple y clásica estructura de clasificador por NN se ha implementado con éxito en diferentes esquemas de condición de monitoreo y diagnóstico (Zhang y Wang, 2013 b). Además de proporcionar la clasificación y diagnóstico de fallas, este clasificador por NN también proporcionó la probabilidad de diagnóstico debido a que utilizó una función sigmoide como función de activación en su capa de salida; por lo tanto, el resultado de clasificación que se proporcionó está relacionado con un valor de

probabilidad. Para el entrenamiento se utilizó la regla de retropropagación para la estimación del gradiente y el gradiente conjugado escalado como técnica de minimización.

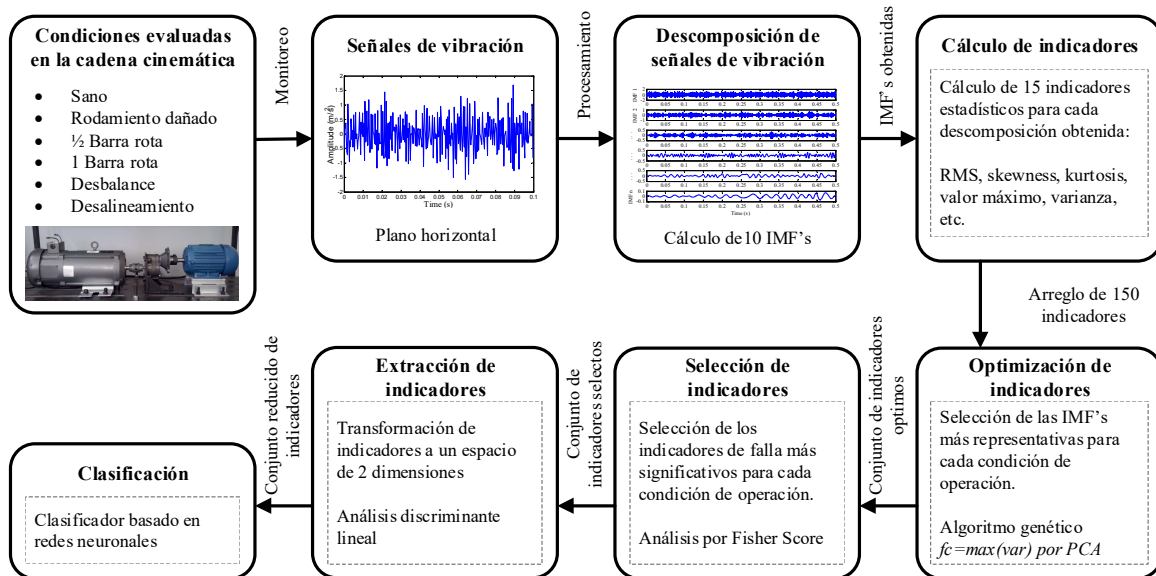


Figura 17. Diagrama bloques empleado durante el monitoreo y diagnóstico de múltiples fallas en el motor de inducción.

### 3.5 Evaluación de la confiabilidad del diagnóstico de fallas en la cadena cinemática

Para realizar el análisis de la confiabilidad del diagnóstico de fallas en la cadena cinemática, se calculó el coeficiente Alfa de Cronbach ( $\alpha$ ) mediante la ecuación (2.39). Como se mencionó y en específico para este trabajo, este coeficiente  $\alpha$  describirá la confiabilidad del promedio de los resultados obtenidos de  $k$  mediciones evaluadas, es decir, el coeficiente  $\alpha$  nos dará la medida de la consistencia interna de los resultados obtenidos como una medida de confiabilidad. En este sentido, para obtener el coeficiente  $\alpha$  se evaluaron las matrices de confusión de los resultados de diagnóstico obtenidos de la evaluación de diferentes condiciones de estado en la caja de engranes y el motor de inducción de las secciones 3.3 y 3.4. Estas matrices de confusión evaluadas contenían los valores de clase asignados (diagnóstico obtenido) para cada una de las muestras evaluadas, por lo tanto, para el caso de la caja de engranes se evaluaron cuatro clases diferentes (HLT, 25%, 50% y 75% de desgaste uniforme), y para el motor de inducción se evaluaron seis clases diferentes (HLT, BD, 1/2 BRB, 1 BRB, UNB y MAL). Para este trabajo de investigación, el cálculo del coeficiente  $\alpha$  como medida de confiabilidad es el más apropiado, esto debido a la capacidad que se tiene

por poder analizar matrices con valores de clasificación en la identificación de diferentes clases, así, calculando este valor se podrá conocer la confiabilidad que se tienen en los resultados de diagnóstico, identificación y clasificación de las diferentes fallas evaluadas en la cadena cinemática.

# Capítulo IV

## 4. Resultados y discusiones

En este capítulo se muestran los resultados obtenidos de desarrollar la metodología propuesta de condición de monitoreo y diagnóstico en la detección de fallas en una cadena cinemática, los resultados y sus respectivas discusiones están reportados en el mismo orden en que se realizó la descripción de la metodología propuesta.

### 4.1 Análisis de los efectos generados por la combinación de fallas de la caja de engranes y el motor de inducción

En la primera parte de la identificación de fallas en la cadena cinemática se analizaron los efectos de combinar fallas en la caja de engranes y el motor de inducción, las condiciones evaluadas fueron las tres severidades de desgaste uniforme en una caja de engranes, una condición de rodamiento dañado en un motor de inducción y sus combinaciones.

Durante la experimentación se remplazaron iterativamente los elementos dañados por los elementos de condición sana y se realizó la adquisición de señales de vibración, corriente de estator y velocidad de rotación, además, se utilizaron diferentes frecuencias de operación en el variador de velocidad para alimentar el motor de inducción que impulsa toda la cadena cinemática y observar los diferentes comportamientos de las condiciones evaluadas. Aunque en el variador de frecuencias se fijaron los valores de 5 Hz, 15 Hz y 50 Hz, la frecuencia de operación del motor de inducción fue ligeramente menor en cada uno de los casos debido al deslizamiento en el rotor. Debido a que esta primera parte del diagnóstico se basó en el análisis de componentes frecuenciales de falla en señales de vibración y corriente de estator, fue necesario tener conocimiento de la velocidad de rotación real para poder realizar el cálculo teórico de las componentes frecuenciales de falla de los engranes y el rodamiento. En este sentido, a partir de la velocidad de rotación que se midió con el encoder digital se calcularon estas componentes frecuenciales, en la Tabla 4.1 se muestra un resumen de estas componentes frecuenciales características de las fallas. Para el engrane desgastado se calculó la frecuencia de engranaje ( $f_m$ ) y su segundo armónico ( $2f_m$ ), y para el rodamiento se calculó la frecuencia de su pista exterior ( $f_{BPOF}$ ), su segundo armónico ( $2f_{BPOF}$ );

estas frecuencias de características de falla son la base para realizar el análisis espectral de las señales de vibración. Por otra parte, para el análisis espectral con señales de corriente, se utilizó la frecuencia de rotación real ( $f_r$ ) para el cálculo de una componente de frecuencia que caracteriza la falla de rodamiento dañado ( $f_{BE}$ ) sobre el espectro de corrientes; en caso de los engranes desgastados, aun no existe una formulación teórica que sustente el análisis espectral de señales de corriente para la detección de sus fallos.

Tabla 4.1 Frecuencias características de falla calculadas a partir de la velocidad de rotación del motor de inducción.

Velocidad de giro (rpm)	Frecuencias características de falla (Hz)					
	Engrane		Rodamiento			
	$f_m$	$2f_m$	$f_{BPOF}$	$2f_{BPOF}$	$f_{BE}$	$f_r$
293.4	88.02	176.04	17.50	35	21.99	4.89
889.28	266.79	533.58	53.06	106.12	67.88	14.82
2984.4	895.32	1790.65	178.09	356.18	227.83	49.74

Por lo tanto, para determinar la presencia o no de fallos en la cadena cinemática, se analizaron las señales de vibración mediante la aplicación de la FFT para calcular sus espectros, y para las señales de corriente se obtuvieron los espectros para un análisis de densidad espectral de potencias (PSD-Power Spectral Density). En este sentido, en la Figura 18 se muestra uno de los espectros de vibraciones que se obtuvo cuando en la caja de engranes se encontraba el engrane sano, y en la Figura 19 se muestra el espectro de vibraciones que se generó cuando en la caja de engranes se encontraba el engrane con 50 % de desgaste uniforme; en ambas condiciones en el variador de frecuencias se fijó un valor de 15 Hz. Sobre estos espectros de vibraciones fue posible detectar componentes característicos como la frecuencia de rotación ( $f_r = 14,65 \text{ Hz}$ ), la frecuencia de engranaje ( $f_m = 267,3 \text{ Hz}$ ), la frecuencia de la pista exterior del rodamiento ( $f_{BPOF} = 52,73 \text{ Hz}$ ) y sus correspondientes armónicos  $2f_m = 534,7 \text{ Hz}$ ,  $2f_{BPOF} = 104 \text{ Hz}$ ,  $4f_{BPOF} = 208 \text{ Hz}$ ).

Como se muestra en el espectro de vibraciones para la condición sana (Figura 18), existen una gran cantidad de componentes que quizás no tengan relación alguna con las componentes características de falla, sin embargo, las componentes de frecuencia que caracterizan a los diferentes elementos con falla tienen amplitudes de vibración bajas. Aunque la aparición de vibraciones en cualquier maquinaria es inevitable por las condiciones de operación, para realizar acciones de condición de monitoreo se debe de tener como patrón

un rango de amplitudes de vibraciones que caractericen la condición sana de la maquinaria, y que además después será útil para determinar la condición de la maquinaria. Por lo tanto, al comparar los espectros de vibraciones correspondientes a la condición sana y la de 50 % de desgaste uniforme en la caja de engranes (Figura 18 y Figura 19), se observó que la amplitud de la frecuencia de engranaje ( $f_m$ ) incremento significativamente, este incremento también se presentó en su respectivo armónico ( $2f_m$ ); además en las bandas laterales de estas frecuencias aparecieron componentes adicionales; en este sentido, el incremento en amplitud de las vibraciones es un indicador característico de la aparición de fallas.




Figura 18. Espectro de vibraciones para la condición sana de la cadena cinemática y cuando el motor de inducción se operó a 15Hz.

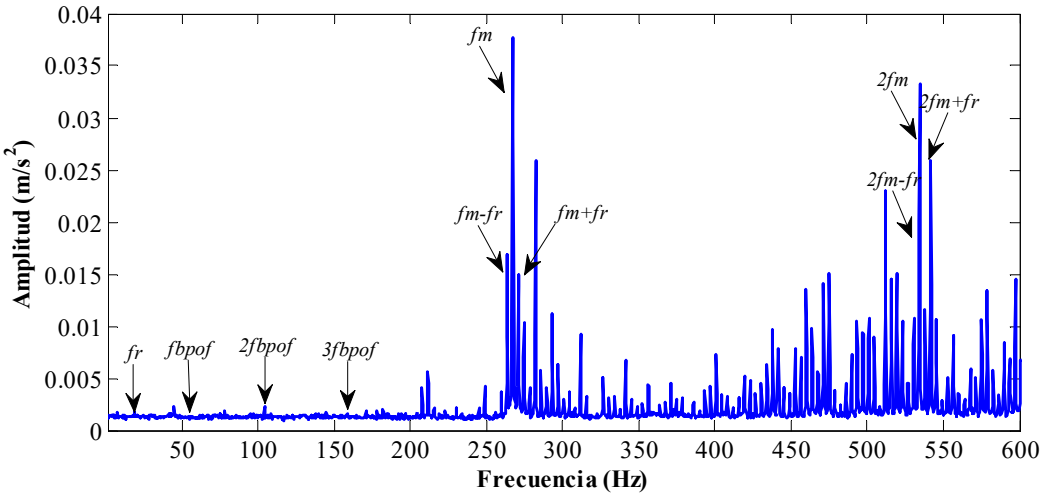




Figura 19. Espectro de vibraciones para la condición de 50% de desgaste uniforme de la caja de engranes, motor de inducción en estado sano y frecuencia de operación de 50Hz.

En la Figura 20 se muestran otros espectros de vibraciones obtenidos cuando el variador de frecuencias operó a 5 Hz y en la cadena cinemática se evaluó la condición sana, 75 % de desgaste uniforme, rodamiento dañado y sus combinaciones, sobre cada uno de estos espectros de vibraciones fue posible hacer la identificación de la frecuencia de rotación real ( $f_r = 4.83 \text{ Hz}$ ), la componente de frecuencia asociada al engrane ( $f_m = 87.89 \text{ Hz}$ ) y al rodamiento ( $f_{BPOF} = 17.21 \text{ Hz}$ ) y sus respectivos armónicos ( $2f_m = 176.1 \text{ Hz}$ ,  $3f_m = 264.8 \text{ Hz}$ ,  $2f_{BPOF} = 34.06 \text{ Hz}$ ,  $3f_{BPOF} = 53.1 \text{ Hz}$ ).


Por lo tanto, para esta condición de operación del variador, el espectro de vibraciones de la condición sana mostrado en la Figura 20a fue considerado como el patrón referencia sobre el cual se compararon las condiciones de falla. Así, del espectro de la Figura 20b que se obtuvo de las vibraciones generadas bajo la condición de rodamiento dañado y caja de engranes en condición sana, se observó que las amplitudes de las frecuencias características de los engranes y el rodamiento se mantuvieron aproximadamente en el mismo nivel; pero, aparecieron componentes de frecuencia en las regiones cercanas a las bandas laterales de frecuencia de engranaje y sus armónicos. Por otra parte, sobre el espectro de la Figura 20c obtenido de evaluar la condición de 75 % de desgaste uniforme sin rodamiento dañado, se generaron incrementos de amplitud en el segundo y tercer armónico de la frecuencia de engranaje ( $2f_m$  y  $3f_m$ ) debido a la presencia del desgaste uniforme en la caja de engranes. Y cuando se combina la falla de rodamiento dañado con la falla de 75 % de desgaste uniforme en el engrane, las frecuencias características de falla presentaron un incremento en amplitud como muestra el espectro de la Figura 20d; de este espectro fue posible hacer la detección de la falla del desgaste en el engrane debido al incremento de amplitud que se generó en los armónicos de la frecuencia de engranaje. Debido a que la aparición de vibraciones fue inherente a la condición de operación de la caja de engranes, la identificación de falla por defecto en el rodamiento se vio limitada por generar componentes de frecuencia inferiores a las que la caja de engranes género.



(a)




(b)



(c)





(d)  
 Figura 20. Espectro de vibraciones para cuando el motor de inducción se operó a 5Hz para las condiciones de: (a) cadena cinemática sana, (b) rodamiento dañado del motor de inducción, (c) 75% de desgaste uniforme en la caja de engranes, y (d) combinación de rodamiento dañado con desgaste uniforme de 75%.

A pesar de que el acelerómetro fue instalado en la parte central de la cadena cinemática, las vibraciones que se generaron por la falla de rodamiento dañado no fueron tan significativas como para ser transmitidas a través del eje que acopla en el motor de inducción y a caja de engranes. Además, en los espectros mostrados también hay componentes de frecuencia que no están relacionados a alguno de los elementos evaluados, todos estos componentes de frecuencia se deben a la composición de la cadena cinemática.

Un resumen de los resultados numéricos del análisis de componentes frecuenciales se muestran de la Tabla 4.2 a la Tabla 4.5, estas tablas están divididas según la frecuencia de operación utilizada en el variador de frecuencias (5 Hz y 15 Hz), y a su vez se dividen por combinar o no la falla de rodamiento dañado con las diferentes severidades de desgaste uniforme evaluada.

De estos resultados tabulados se realizó una clara identificación de la aparición de fallas de desgaste en los engranes al observar los incrementos de la amplitud de las componentes de la frecuencia de engranaje y sus armónicos ( $f_m$ ,  $2f_m$  y  $3f_m$ ), y cuando la falla de rodamiento dañado no está presente. Por otra parte, ante la presencia de la falla de rodamiento dañado, las amplitudes de frecuencia de la caja de engranes también presentan incrementos de forma irregular; este fenómeno se generó por la combinación de los fallos y la transición de las vibraciones por toda la cadena cinemática. Y a pesar de que la falla de

rodamiento dañado no se detectó satisfactoriamente, se pudo comprobar que las vibraciones generadas por el rodamiento modifican la condición de operación en toda la cadena cinemática.

Tabla 4.2 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 5 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )					
	$f_m$	$2f_m$	$3f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	1.160	1.291	1.223	1.141	1.197	1.226
25%	1.193	1.372	1.805	1.252	1.228	1.198
50%	1.146	1.454	2.694	1.218	1.265	1.284
75%	1.131	2.737	1.588	1.387	1.424	1.530

Tabla 4.3 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 5 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )					
	$f_m$	$2f_m$	$3f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	1.155	1.220	1.271	1.123	1.177	1.111
25%	1.203	1.275	1.397	1.212	1.169	1.223
50%	1.206	1.364	2.774	1.217	1.170	1.338
75%	1.188	1.708	1.215	1.190	1.111	1.178

Tabla 4.4 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 15 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )					
	$f_m$	$2f_m$	$3f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	3.979	2.095	6.050	1.182	1.144	1.305
25%	15.96	7.438	6.821	1.322	1.178	1.363
50%	37.75	33.31	28.46	1.347	1.405	1.347
75%	42.29	34.48	30.09	1.461	1.322	1.345

Tabla 4.5 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 15 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )					
	$f_m$	$2f_m$	$3f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	2.482	4.673	8.622	1.204	1.352	1.427
25%	6.522	6.016	9.611	1.276	1.381	1.233
50%	13.93	9.154	13.11	1.432	1.414	1.427
75%	5.154	6.235	6.344	1.375	1.284	1.412

Los resultados obtenidos del análisis espectral a frecuencias bajas de operación (5 Hz y 15 Hz) fueron adecuados para la detección del desgaste en la caja de engranes, mientras que del análisis espectral realizado a frecuencias de operación más altas (50 Hz) no se

obtuvieron resultados tan significativos; esto debido a que a frecuencias de operación más altas la aparición de vibraciones es aún más inherente a la operación de trabajo. Respecto a la falla de desgaste uniforme, debido a que las componentes de la frecuencia de engranaje no presentaron un incremento monótonico de su amplitud, estos resultados que se obtuvieron no permitieron hacer una identificación clara de la aparición de esta falla. De forma similar para la falla de engrane dañado tampoco fue perfectamente detectada mediante el análisis espectral a frecuencias de operación altas; aunque ambas fallas no pudieron ser correctamente detectadas, las oscilaciones en las amplitudes de vibración son indicador de que la condición de la cadena cinemática no es la adecuada. En la Tabla 4.6 se muestran las amplitudes de las componentes frecuenciales de falla para las diferentes condiciones evaluadas en la caja de engranes cuando en el variador de frecuencias se fijó el valor de 50 Hz y la condición del rodamiento fue sana, y en la Tabla 4.7 se muestran las componentes de frecuencia de falla para las diferentes condiciones de la caja de engranes, rodamiento dañado y cuando en el variador se usaron de 50 Hz.

Tabla 4.6 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 50 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )			
	$f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	26.73	2.491	5.538	8.179
25%	31.67	1.551	1.721	8.298
50%	40.92	1.659	4.265	17.15
75%	19.69	2.628	3.474	12.49

Tabla 4.7 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 50 Hz.

Condición	Amplitud ( $\times 10^{-3}$ m/s <sup>2</sup> )			
	$f_m$	$f_{BPOF}$	$2f_{BPOF}$	$3f_{BPOF}$
HLT	28.79	3.832	1.248	3.326
25%	10.27	4.005	1.527	7.018
50%	58.26	5.194	1.609	5.52
75%	23.79	6.364	1.811	5.857

En esta primera parte de identificación de fallas también se propuso el análisis espectral de las señales de corriente con la finalidad de observar los efectos causados por las vibraciones que generan los fallos de desgaste uniforme en los engranes, rodamiento dañado y sus combinaciones. En este sentido, para cada experimento se obtuvo espectro de densidad de potencias de las señales de corriente del motor de inducción, este análisis se centró en

observar las modificaciones que sufren los espectros alrededor de la frecuencia de operación  $f_s$ . Este análisis espectral de corrientes careció de información relacionada a las condiciones evaluadas cuando se analizó el espectro obtenido por fijar en el variador de frecuencias un valor de 5 Hz; de forma contraria, fue posible identificar cambios importantes sobre los espectros de corrientes cuando en el variador de frecuencias se fijaron los valores de 15 Hz y 50 Hz.

Las condiciones de falla evaluadas en la caja de engranes y el motor de inducción tuvieron mayor influencia sobre los espectros de corrientes cuando el variador de frecuencias opero a 50 Hz, en la Figura 21a se muestran los espectros de corrientes para las diferentes condiciones evaluadas en la caja de engranes, sano, 25 %, 50 % y 75 % de desgaste; sobre este espectro fue posible observar los efectos que genero el efecto del desgaste uniforme sobre los consumos de corriente del motor de inducción. Las bandas laterales que aparecen en ambos lados de la frecuencia de operación  $f_s$  que es 50 Hz son algunos de los efectos que generó la falla de desgaste, además, debido a que estas bandas laterales se encuentran separadas a una distancia de  $f_r/4$  de la frecuencia de alimentación  $f_s$ , esta separación coincide exactamente con el ratio de reducción de la caja de engranes (4:1). Aunque, ante la presencia de las condiciones del desgaste las bandas laterales no presentaron un incremento monótonico en su amplitud, la modificación de sus amplitudes permite saber de la existencia de este tipo de falla, y estos resultados podrían complementarse con el análisis espectral de vibraciones para tener certeza sobre la condición de la cadena cinemática.

En la Figura 21b se muestran otros espectros de corrientes que corresponden a la condición sana, rodamiento dañado, 75 % de desgaste y la combinación de ambos fallos; en estos espectros se observa que las amplitudes de las bandas laterales a la frecuencia de operación  $f_s$  son modificadas ante la aparición de la falla causada por el rodamiento dañado. En este sentido, se profundizo más en el análisis de la componente de frecuencia de fallo del rodamiento  $f_{BE}$ , se pudo identificar la presencia de falla de rodamiento dañado al comparar las amplitudes de esta componente; por lo que, mediante el análisis espectral en corrientes fue posible determinar la presencia de falla generada por el rodamiento dañado. Con el fin de simplificar los resultados, en la Tabla 4.8 se muestra el valor numérico de las componentes de frecuencia principal con las que se efectuó el análisis, donde destaca la frecuencia de operación dada por el variador  $f_s$ , cinco frecuencias adicionales ( $a$ ,  $b$ ,  $c$ ,  $d$ ,  $e$ ) y la frecuencia

de fallo del rodamiento  $f_{BE}$ . Y en la Tabla 4.9 y Tabla 4.10 se muestra un resumen de las amplitudes de estas frecuencias mencionadas.

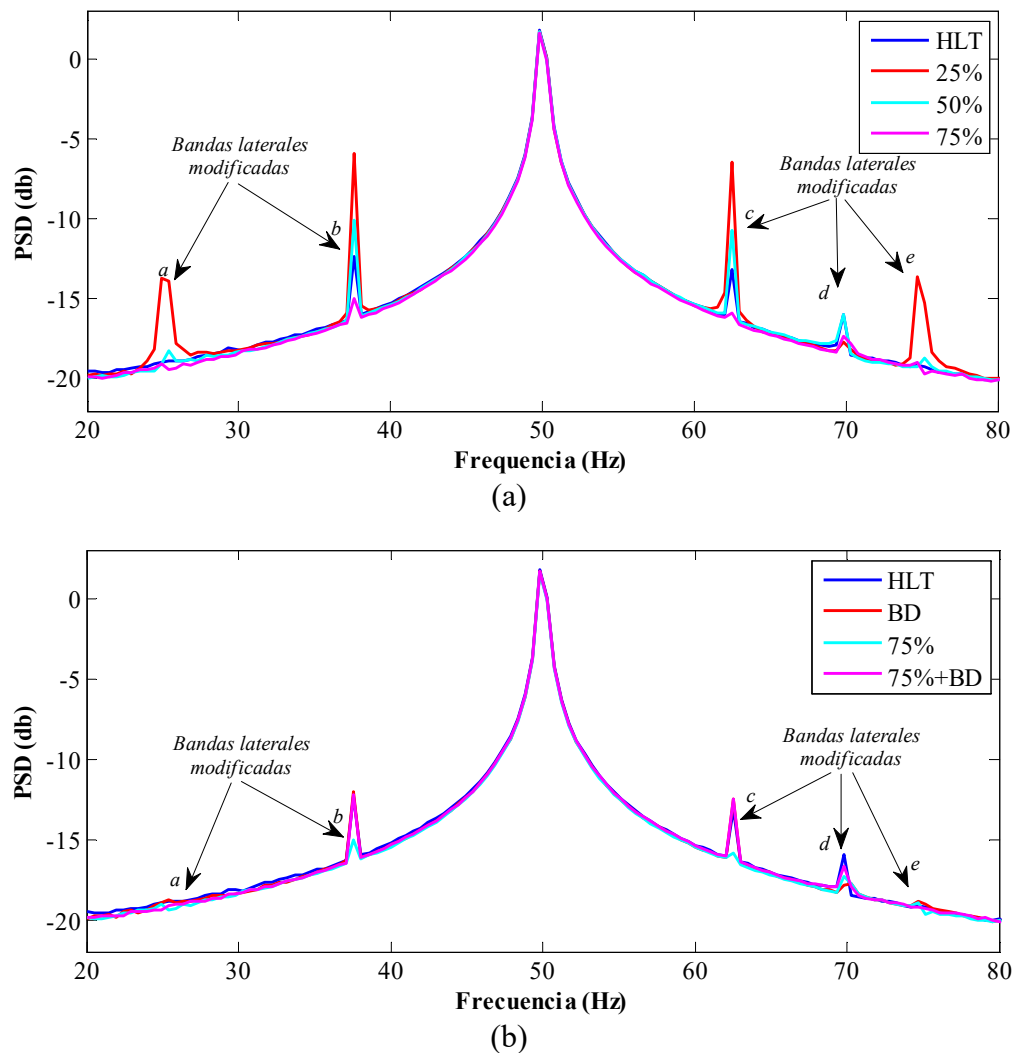


Figura 21. Espectro de densidades de potencia de señales de corriente para cuando el motor de inducción se operó a 50 Hz para las condiciones de: (a) diferentes severidades de desgaste en la caja de engranes, (b) combinación de falla de desgaste uniforme con rodamiento dañado.

Tabla 4.8 Componentes de frecuencia a analizar en los espectros de corriente.

Frecuencia usada en el variador (Hz)	Frecuencias localizadas alrededor de $f_s$ (Hz)						
	$f_s$	$a$	$b$	$c$	$d$	$e$	$f_{BE}$
15	15.14	3.90	7.81	22.46	26.37	29.79	83.02
50	49.81	25.39	37.60	62.50	69.82	74.71	277.64

Tabla 4.9 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado sin rodamiento dañado y variador de frecuencias a 50 Hz.

Frecuencia del in VFD (Hz)	Amplitudes de frecuencias (db)						
	$f_s$	$a$	$b$	$c$	$d$	$e$	$f_{BE}$
HLT	1.75	-18.86	-12.34	-13.13	-15.99	-19.16	-28.39
25%	1.68	-13.93	-5.90	-6.50	-17.74	-13.59	-27.76
50%	1.68	-18.22	-10.13	-10.76	-16.00	-18.73	-27.30
75%	1.58	-19.40	-15.02	-15.9	-17.33	-18.97	-27.97

Tabla 4.10 Amplitudes de las componentes de frecuencia de falla para cada condición de engrane desgastado, rodamiento dañado y variador de frecuencias a 50 Hz.

Frecuencia del VFD (Hz)	Amplitudes de frecuencias (db)						
	$f_s$	$a$	$b$	$c$	$d$	$e$	$f_{BE}$
HLT	1.66	-18.74	-12.03	-12.55	-17.85	-18.84	-26.46
25%	1.67	-13.27	-6.00	-6.54	-17.94	-13.24	-21.74
50%	1.63	-15.65	-8.48	-9.01	-17.98	-15.82	-24.28
75%	1.67	-19.16	-12.25	-12.51	-16.64	-19.24	-26.34

#### 4.2 Identificación y clasificación de las diferentes severidades de desgaste uniforme en engranes

En la segunda parte de la identificación de fallas en la cadena cinemática se realizó el monitoreo y diagnóstico de las cuatro condiciones diferentes evaluadas en la caja de engranes: HLT, 25%, 50% y 75% de desgaste uniforme.

Durante la experimentación se evaluaron iterativamente cada una de las condiciones de falla y se hizo la adquisición de las vibraciones generadas; durante la evaluación de cada de las condiciones se emplearon diferentes frecuencias de operación en el variador de frecuencia (5Hz, 15Hz y 50Hz). Las señales de vibración adquiridas y almacenadas constaron de noventa mediciones relacionadas con la operación de trabajo de la caja de engranes, donde cada una estas mediciones tuvieron una duración de un segundo. Posteriormente, se estimó un conjunto de 15 indicadores de cada una de las mediciones para generar un patrón característico de vibraciones para cada una de las condiciones evaluadas, así, cada una de las condiciones evaluadas a diferentes frecuencias de operación quedó representada por un conjunto de 15 indicadores con 90 muestras.

A pesar de que este conjunto de indicadores estadísticos ofrece una buena caracterización de las señales, no todos tienen la misma cantidad de información relacionada con las condiciones de falla. A este respecto, con el objetivo de conservar indicadores

estadísticos más representativos, los conjuntos de indicadores estimados se sometieron a un proceso de análisis mediante un enfoque reducción de indicadores, en el que se incluyó una selección y extracción de indicadores.

En la etapa de selección de indicadores se analizaron las capacidades discriminativas de los indicadores estadísticos mediante el cálculo de su coeficiente de Fisher. Este análisis de indicadores se aplicó individualmente a los conjuntos de indicadores estadísticos de cada uno de los pares de condiciones sano-fallo, donde para todas las combinaciones posibles en subconjuntos de uno, dos y tres indicadores estadísticos se estimó el coeficiente de Fisher. Debe resaltarse que mediante el análisis individual para los tres pares de condiciones sana-fallo se filtraron los indicadores estadísticos con mejores capacidades discriminativas. Los tres pares de condiciones sano y daños son: sano-25% de desgaste, sano-50% de desgaste y sano-75% de desgaste. En este proceso de selección los recursos computacionales pudieron verse comprometidos debido a que el análisis mediante coeficientes de Fisher representa un problema de combinación entre indicadores, por eso es que este análisis se limitó a realizar combinaciones de máximo tres indicadores estadísticos. Después de la evaluación de todas las posibles combinaciones, los conjuntos de indicadores fueron ordenados de acuerdo su relevancia determinada por el coeficiente de Fisher; es decir, los conjuntos de indicadores con mejores capacidades discriminativas produjeron valores grandes para el coeficiente de Fisher. Entonces, con el objetivo de filtrar los mejores indicadores estadísticos, el primer subconjunto que se enlistó fue considerado como el mejor conjunto de indicadores con capacidades de distinguir entre el par de condiciones sano-fallo correspondiente.

Por lo tanto, los subconjuntos de indicadores estadísticos que mejor describen a cada una de las condiciones consideradas se obtuvieron mediante este proceso de selección, en la Tabla 4.11 se muestra el detalle de cada uno de los subconjuntos de indicadores estadísticos seleccionados para las condiciones consideradas a diferentes frecuencias de operación. Debe aclararse que el detalle de los subconjuntos de indicadores de la Tabla 4.11 corresponde al primer subconjunto que se enlistó en términos del coeficiente de Fisher, es decir, es el subconjunto de indicadores con el coeficiente de Fisher más grande, además, estos subconjuntos se obtuvieron de la combinación de tres indicadores estadísticos. Por lo tanto,

los valores de los coeficientes mostrados corresponden al coeficiente de Fisher generado por los indicadores estadísticos que componen a cada uno los subconjuntos seleccionados.

Asimismo, debe considerarse que coeficientes de Fisher igual a 1 significan que la estimación de dispersión dentro de la clase es igual a la estimación de dispersión entre clases. Por lo tanto, los indicadores estadísticos con mejores capacidades de discriminación son aquellos que tienden a generar coeficientes de Fisher superior a 1. Por consiguiente, de acuerdo con los valores de la Tabla 4.11, los subconjuntos de indicadores seleccionados tienen capacidades discriminativas ventajosas para la diferenciación entre los pares de clases sano-fallos. Además, se observó que un indicador estadístico puede aparecer repetido en los diferentes subconjuntos de indicadores seleccionados para la misma condición de trabajo de la caja de engranes, y aunque esto suceda, este indicador debe considerarse sólo una vez para formar el conjunto final de indicadores seleccionadas. Por ejemplo, considerando los subconjuntos de indicadores seleccionados obtenidos cuando la frecuencia de operación fue 5 Hz, el conjunto final de indicadores estadísticos seleccionados se integró por el SRM, la desviación estándar, el RMS, la media y la varianza.

Tabla 4.11 Detalle de los subconjuntos de indicadores seleccionados por considerar la combinación de tres indicadores para el cálculo del coeficiente de Fisher.

Condición	Frecuencia de operación					
	5 Hz		15 HZ		50 Hz	
	Conjunto de indicadores seleccionados	Coefficiente de Fisher calculado	Conjunto de indicadores seleccionados	Coefficiente de Fisher calculado	Conjunto de indicadores seleccionados	Coefficiente de Fisher calculado
25 %	SRM-desviación estándar-RMS	1693.43	Desviación estándar - RMS-SMR	34946.22	Desviación estándar - RMS-varianza	366.91
50 %	Media-varianza-desviación estándar	419.58	Media-desviación estándar - varianza	877.73	Mean-S. factor RMS-S. factor SMR	408.61
75 %	Desviación estándar-varianza-RMS	74.92	SRM-RMS-Desviación estándar	684.15	RMS desviación estándar - varianza	1620.95


Posteriormente, en el proceso de extracción de indicadores, los subconjuntos de indicadores seleccionados fueron sometidos a un proceso de compresión y transformación de



base a través de la técnica LDA. Así, a través de esta estrategia de extracción de indicadores se obtuvo un nuevo subconjunto de indicadores, y estos indicadores extraídos están compuestos por una combinación ponderada de cada uno de los indicadores estadísticos previamente seleccionados. Como resultado de la transformación de la base, fue posible obtener una representación visual en un espacio bidimensional de las condiciones consideradas.

Debido a cada una de las condiciones consideradas se evaluó para tres frecuencias de operación diferentes, entonces, la extracción de indicadores se aplicó individualmente a los subconjuntos de indicadores seleccionados para cada una de las diferentes frecuencias de operación. En la Figura 22 se muestran las proyecciones resultantes de los conjuntos de indicadores extraídos a través de la LDA para las tres frecuencias de operación diferentes, 5Hz, 15Hz y 50Hz.

Como se esperó, en las tres proyecciones resultantes para las diferentes frecuencias de operación, se obtuvo una excelente separación entre las clases de las condiciones consideradas. Aunque, algunos puntos de datos de clases diferentes tendieron a aparecer cerca unos de los otros, los centros de los datos de las clases se separan perfectamente. Además, la efectividad y aplicabilidad de esta estrategia de diagnóstico queda justificada debido a que no se produjeron superposiciones entre la condición sana de la caja de engranes y las diferentes condiciones de falla.



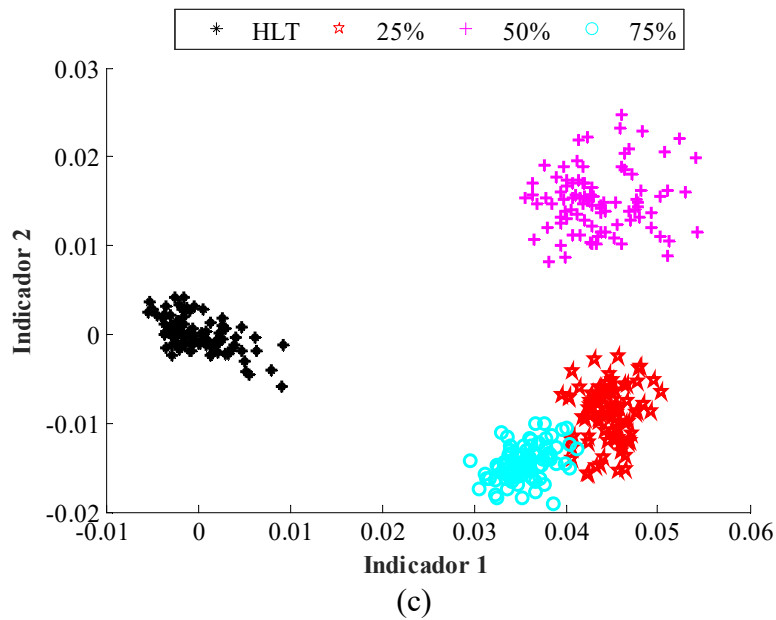
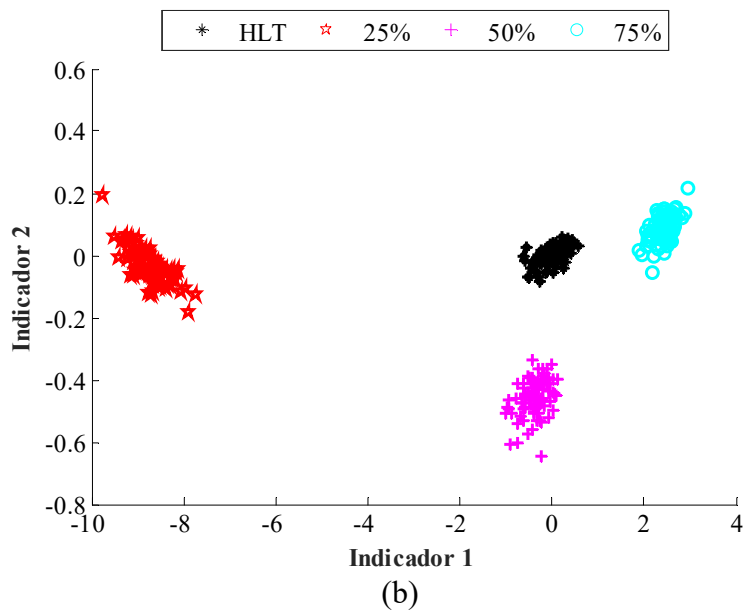


Figura 22. Proyecciones de los conjuntos de indicadores extraídas mediante la LDA para cuando el motor opero a: (a) 5Hz, (b) 15Hz y (c) 50Hz.

Respecto a la clasificación, se propuso usar un clasificador basado en inferencia difusa para realizar el diagnóstico y clasificación de fallos, mediante la aplicación sucesiva del método de reducción de indicadores (selección y reducción de indicadores) se obtuvo una excelente caracterización de las condiciones consideradas; esta caracterización facilito realizar la tarea de diagnóstico, y por lo tanto una estructura simple en el clasificador

permitirá obtener resultados precisos sin un excesivo coste computacional. Por lo tanto, en la estructura de un clasificador de inferencia difusa se evaluaron los diferentes conjuntos de indicadores extraídos por la LDA, esta evaluación se hizo por medio de la evaluación de funciones de membresía para determinar el grado de asociación con un evento difuso específico. Después de esto, el diagnóstico se obtuvo al calcular el consecuente de cada función de pertenencia en el sistema de inferencia difusas, y este consecuente fue determinado por la función de membresía de tipo Sugeno, el clasificador fue entrenado a lo largo de 50 épocas.

Con el objetivo de demostrar la efectividad de esta estrategia de diagnóstico y obtener resultados estadísticamente significativos, este clasificador se evaluó bajo un esquema de validación cruzada de 5 veces. En este sentido, los conjuntos de indicadores extraídos compuestos por 360 muestras (90 muestras por condición) se consideran como la base de datos original. Luego, esta base de datos se dividió en dos conjuntos de datos diferentes. El primer conjunto compuesto por 288 muestras (72 muestras por condición), se utilizó para el entrenamiento del clasificador, y el segundo conjunto con 72 muestras (18 muestras por condición), se utilizó para probar el clasificador. Por lo tanto, con respecto al desempeño de la clasificación, se usó toda la variabilidad de las bases de datos disponibles y, mediante la consideración del esquema de validación cruzada de 5 veces, se obtienen cinco ratios de clasificación. Estos ratios de clasificación fueron promediados, en la Tabla 4.12 se muestra el resumen de las medias de estos ratios de clasificación alcanzados durante el entrenamiento y prueba del clasificador difuso para las diferentes condiciones de operación. Debe mencionarse que estos ratios de clasificación mostraron un comportamiento estable bajo el esquema validación cruzada de 5 veces, y para las diferentes frecuencias de operación los ratios de clasificación estuvieron dentro de los rangos de 94.3% a 99.8% durante el entrenamiento y 92.2% y 99.1% para la etapa de prueba del clasificador.

Tabla 4.12 Rendimiento de la clasificación obtenida durante el entrenamiento y prueba del sistema de inferencia Fuzzy bajo las condiciones consideradas a diferentes frecuencias de operación.

Frecuencia de operación	Entrenamiento	Prueba
5 Hz	99.32%	98.88%
15 Hz	99.82%	99.1%
50 Hz	94.3%	92.2%

### 4.3 Detección y clasificación de múltiples fallas en el motor de inducción

En la tercera parte de la identificación de fallas de la cadena cinemática se evaluaron diferentes condiciones de operación en el motor de inducción, para el monitoreo y diagnóstico de las múltiples fallas evaluadas se usaron las señales de vibración del plano perpendicular al eje de rotación del motor de inducción; y estas señales contenían noventa muestras consecutivas de un segundo de la operación de la cadena cinemática para las diferentes condiciones consideradas. Posteriormente, a estas señales se les aplicó una descomposición por medio de la EMD, y para cada una de las noventa muestras de las descomposiciones que se obtuvieron se calculó el conjunto de 15 indicadores estadísticos. En consecuencia, se estimó un conjunto de indicadores de alta dimensionalidad para cada condición considerada, donde cada uno de estos conjuntos quedo compuesto por 90 muestras con 150 indicadores de estadística.

Después, durante el proceso de optimización con el GA, se utilizó la varianza acumulada por dos y tres de las componentes principales para comparar los resultados de las IMF's optimizadas, y con esto se observó que el GA generaba el mismo conjunto de IMF's optimizadas. Aunque los resultados son similares, hubo una clara diferencia en los recursos computacionales. Es decir, cuando se consideraron tres componentes principales, la carga computacional aumento, y como consecuencia el tiempo de convergencia también aumento aproximadamente dos veces en comparación con el tiempo de convergencia de cuando fueron consideradas solamente dos componentes principales. Con respecto a la varianza acumulada, al considerar tres componentes, el porcentaje de varianza acumulada fue cerca del 3% mayor que la varianza acumulada calculada cuando se consideraron sólo dos componentes. En la Tabla 4.13 se enlistan los conjuntos de IMF's optimizados para todas las condiciones consideradas, para estos conjuntos de IMF's optimizadas se obtuvo un porcentaje de varianza acumulada mayor al 75 % que es considera como un buen número que representa una excelente concentración de la variabilidad de los datos; en la Tabla 4.13 también se muestran los porcentajes de varianza acumulada y el detalle de los indicadores estadísticos con mayor contribución en las dos componentes principales. Respecto al proceso de optimización, este se detuvo por alcanzar el número máximo de generaciones, y para todos los procesos de optimización se obtuvo un buen desempeño; en la Figura 23 se muestran las gráficas del desempeño alcanzado por el GA en términos de la varianza acumulada durante la

optimización de las IMF's, para todas las condiciones consideradas después de las 20 primeras generaciones el mejor individuo mostró su mejor resultado.

Tabla 4.13 Detalle del conjunto indicadores estadísticos obtenidos de las IMF's optimizadas al considerar dos componentes principales en el proceso de optimización.

Condición	IMFs optimas	% $\sigma$	Indicadores estadísticos con mejor atribución en dos componentes principales
Rodamiento dañado	IMF1, IMF2	82.9%	Valor máximo, RMS, SRM, desviación estándar, varianza, RMS factor forma, SRM factor forma, factor cresta, factor de latitud, kurtosis.
½ Barra rota	IMF1	84.2%	Valor máximo, RMS, SRM, desviación estándar, varianza, RMS factor forma, SRM factor forma, factor cresta, factor de latitud, factor impulso.
1 Barra rota	IMF1	92.3%	Valor máximo, RMS, SRM, desviación estándar, varianza, RMS factor forma, SRM factor forma, factor cresta, factor de latitud, factor impulso, kurtosis, sexto momento.
Desbalance	IMF1	92.4%	Media, Valor máximo, RMS, SRM, desviación estándar, varianza, RMS factor forma, SRM factor forma, factor cresta, factor de latitud, factor impulso, kurtosis, sexto momento.
Desalineamiento	IMF1, IMF2	91.1%	Valor máximo, RMS, SRM, desviación estándar, varianza, RMS factor forma, SRM factor forma, factor cresta, factor de latitud, factor impulso, kurtosis, sexto momento

En esta primera etapa de optimización se eliminó la información redundante, para demostrar que existe una diferencia entre la variabilidad de los datos de conjuntos optimizados y un conjunto arbitrario, se aplicó la PCA a el conjunto de IMF's optimizadas de la condición de desalineamiento que está compuesto por los primeros dos modos intrínsecos (IMF1 y IMF2). Y como se mostró en la Tabla 4.13, la varianza acumulada que generan los indicadores estadísticos de estos dos modos (IMF1 y IMF2) es de 91.1% en dos componentes principales; la representación de la dispersión de los datos obtenida se muestra en la Figura 24. Así, para comprobar que este conjunto óptimo de IMF's tiene mayor varianza acumulada en comparación con otro conjunto aleatorio, se utilizó un conjunto aleatorio de IMF's compuesto por los tres últimos modos (IMF8, IMF9 y IMF10) para calcular su varianza acumulada. Para esto se evaluaron en la PCA los 45 indicadores estadísticos que le corresponden al conjunto de IMF's, para este caso se acumuló una varianza del 36.9% en las

dos componentes principales de la PCA, en la Figura 25 se muestra la dispersión de los puntos para generada por el conjunto aleatorio de IMF's. De la Figura 24 y Figura 25 se puede observar que existe una diferencia clara entre las dispersiones de los datos, a partir de estos resultados también se demuestró que, no toda la información relacionada con la condición de la cadena cinemática es útil en esquemas de condición de monitoreo y diagnóstico.

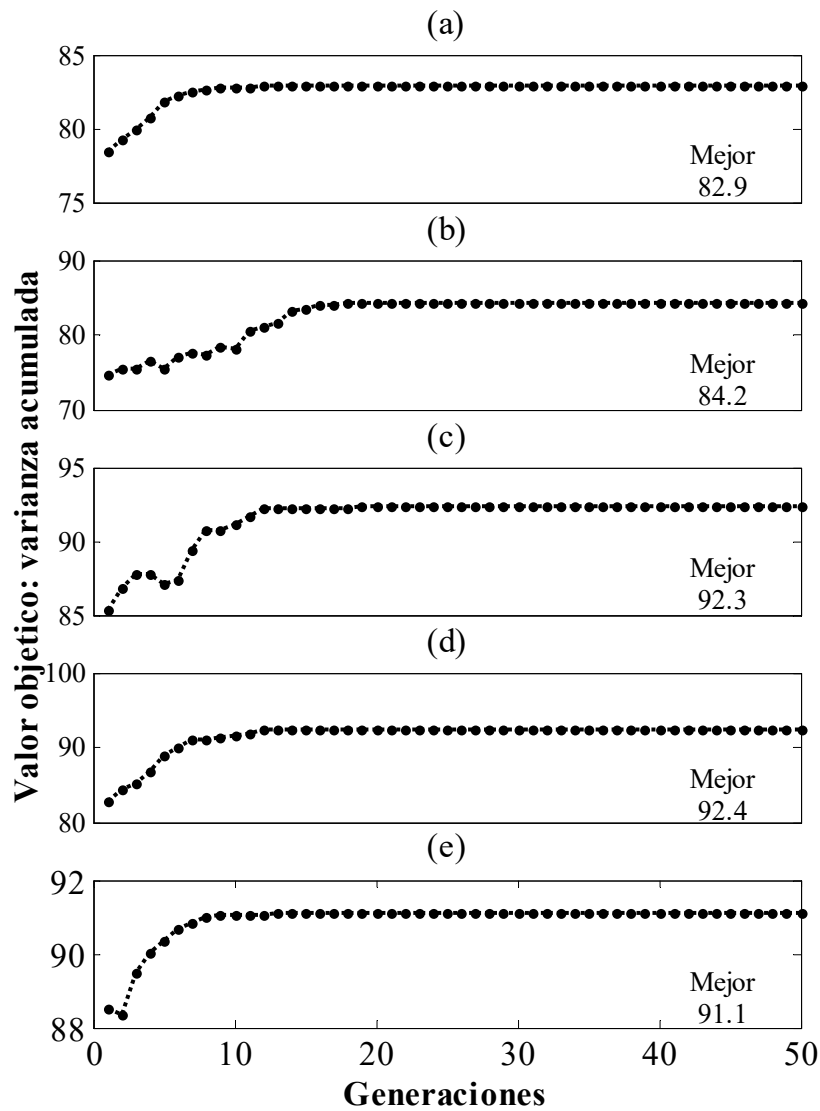


Figura 23. Rendimiento del GA durante la optimización del número de IMF's para representar cada falla considerada, evolución y porcentaje máximo de la varianza acumulada obtenida: (a) rodamiento dañado, (b) ½ barra rota, (c) 1 barra rota, d) desbalance, y e) desalineamiento.




Figura 24. Diagrama de dispersión del conjunto optimizado de IMF's (IMF2 e IMF2) para la condición de desalineación usando dos componentes principales en la PCA.

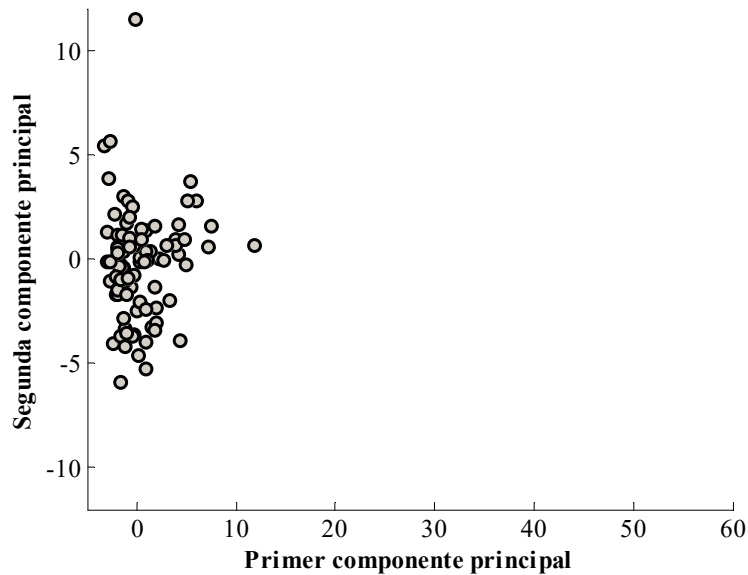


Figura 25 Diagrama de dispersión de un conjunto aleatorio de IMF's (IMF8, IMF9 y IMF10) para la condición de desalineación usando dos componentes principales en la PCA.

La selección de indicadores fue el siguiente proceso considerado en esta estrategia que se propuso, en esta etapa se realizó un análisis de las capacidades discriminativas calculando el coeficiente de Fisher de aquellos indicadores estadísticos que pertenecen al conjunto optimizado de IMF's. Durante este proceso se analizaron todas las combinaciones

de subconjuntos de dos y tres indicadores estadísticos, para este análisis siempre se analizaron las diferentes condiciones de falla con respecto a la condición sana. Después de efectuar todas las combinaciones posibles, los indicadores estadísticos se ordenaron en términos de su coeficiente generado y los tres primeros subconjuntos de indicadores fueron elegidos como los mejores subconjuntos para describir las diferentes condiciones evaluadas.

Con este enfoque de selección se obtuvieron los mejores subconjuntos de indicadores con capacidades de discriminación entre las diferentes condiciones, en la Tabla 4.14 se muestra el detalle de los subconjuntos de indicadores seleccionados, su coeficiente de Fisher y su respectiva IMF a la que pertenecen. Estos coeficientes de Fisher revelaron que existe una buena separabilidad entre las condiciones de BD, 1 BRB, MAL y HLT. Pero, por otra parte, podría aparecer una superposición entre la condición de  $\frac{1}{2}$  BRB, UNB y HLT. Por lo tanto, para obtener una buena separabilidad entre las condiciones consideradas, los coeficientes de Fisher que se esperaban debían haber sido mayor que uno; sin embargo, la combinación de todos los conjuntos de indicadores estadísticos seleccionados aun será evaluados por la técnica de extracción de indicadores LDA. En cuanto al uso de subconjuntos con dos y tres indicadores, los resultados no fueron significativamente diferentes, pero cuando se consideran tres indicadores estadísticos, el tiempo de ejecución de la técnica fue de al menos del doble comparado cuando se usaron dos indicadores.

En la etapa de extracción de indicadores, todos los subconjuntos de indicadores seleccionados fueron sometidos a un proceso de compresión por medio de la técnica LDA, resultado de este proceso de compresión se extrajo un nuevo conjunto de indicadores. Estos nuevos indicadores son la composición en diferente ponderación de los indicadores seleccionados, y también, que este nuevo conjunto de indicadores se pudo proyectar en un espacio bidimensional que representa las diferentes condiciones evaluadas. En la Figura 26 se muestra la proyección en un espacio bidimensional del conjunto de indicadores extraído de la aplicación de la estrategia de reducción de indicadores propuesta (optimización, selección y reducción de indicadores). Y aunque se espera un traslape entre las condiciones de  $\frac{1}{2}$  BRB, UNB y la de HLT, por medio de la LDA se obtuvo una buena separación de las condiciones consideradas. Esta proyección se generó por medio de una matriz de transformación compuesta por un conjunto de valores en diferentes ponderaciones que representan a los indicadores seleccionados, el detalle de estos valores se muestra en la Tabla



4.15. También, debe resaltarse que los valores de esta matriz de transformación que generan los indicadores extraídos y proyectados no se concentran específicamente en uno o dos indicadores estadísticos; y aunque algunos indicadores estadísticos tienen un peso bajo, su fusión con el resto de los indicadores es esenciales para mejorar la separabilidad entre clases de las condiciones consideradas.

Tabla 4.14 Detalle de los subconjuntos de indicadores seleccionados para las diferentes condiciones.

Condición	Indicador estadístico	IMF optimizada	Coefficiente de Fisher
Rodamiento dañado	RMS	IMF1	76.9
	Desviación estándar	IMF1	76.9
	RMS factor forma	IMF2	62.7
	Kurtosis	IMF2	37.8
½ Barra rota	SRM	IMF2	0.13
	Desviación estándar	IMF2	0.13
	Kurtosis	IMF2	0.13
	Sixth momento	IMF2	0.11
1 Barra rota	RMS Shape factor	IMF1	12.4
	Kurtosis	IMF1	6.7
	Kurtosis	IMF2	4.8
	Sexto momento	IMF2	2.1
Desbalance	SMR factor forma	IMF1	0.29
	Valor máximo	IMF2	0.16
	RMS	IMF2	0.16
	Desviación estándar	IMF2	0.15
Desalineamiento	RMS	IMF1	89.0
	SRM	IMF1	88.9
	Desviación estándar	IMF1	80.0
	SMR factor forma	IMF2	67.5




Figura 26. Proyección del conjunto extraído de características resultante de la aplicación de la estrategia de reducción de indicadores híbrida propuesta.

Tabla 4.15 Detalle de la matriz de transformación obtenida por la LDA para generar la proyección de los indicadores seleccionados en un espacio bidimensional.

Indicador estadístico	IMF optimizada	Columna 1	Columna 2
RMS	IMF1	0.570	0.505
SMR	IMF1	0.021	0.026
Desviación estándar	IMF1	0.551	0.481
RMS factor forma	IMF1	0.095	0.055
Kurtosis	IMF1	0.088	0.031
Valor máximo	IMF2	0.014	0.001
RMS	IMF2	0.297	0.476
SMR	IMF2	0.075	0.037
Desviación estándar	IMF2	0.376	0.528
RMS factor forma	IMF2	0.180	0.025
SMR factor forma	IMF2	0.012	0.010
Kurtosis	IMF2	0.258	0.014
Sexto momento	IMF2	0.131	0.009

En cuanto al diagnóstico y clasificación de fallos, se utilizó un clasificador basado en redes neuronales de múltiples capas, además, con la finalidad de obtener resultados estadísticamente significativos y probar el desempeño de la estrategia de diagnóstico propuesta, el clasificador se entrenó y probó bajo un esquema de validación cruzada de cinco veces. Por lo tanto, considerando todas las condiciones, la base de datos original consto de 540 muestras, 90 muestras de cada condición. Esta base de datos se dividió en dos partes

diferentes, la primera parte de 432 muestras se usó para el entrenamiento, 72 muestras por condición y la otra parte de 108 muestras se usó para la prueba, 18 muestras por condición.

Al aplicar el esquema de validación cruzada de cinco veces se obtuvieron cinco razones de clasificación, esto como resultado de cinco iteraciones con particiones complementarias de la base de datos original de entrenamiento y prueba; y con esto se obtuvieron promedios de clasificación del 91% durante el entrenamiento y 92% durante la prueba. Debe aclararse también que los ratios de clasificación obtenidos mediante la validación cruzada de cinco veces presentó un comportamiento estable, es decir, entre el 89.8% y el 91.7% para el entrenamiento y entre 90,7% y 92,8% para la prueba. Con este clasificador, además de generar los ratios de clasificación, asimismo, fue posible calcular y generar un mapa con las regiones de clasificación que ayudaron en el entendimiento e interpretación del diagnóstico dado. En la Figura 27 y **¡Error! No se encuentra el origen de la referencia.** se muestra la las regiones de clasificación en conjunto con las proyecciones de las muestras, estas figuras corresponden a las primeras particiones de las base de datos utilizadas durante el proceso de entrenamiento y prueba del clasificador, respectivamente.

En la Tabla 4.16 y la Tabla 4.17 se muestra el resumen de las respectivas matrices de confusión obtenidas durante proceso el entrenamiento y prueba del clasificador, estas matrices representan la evaluación de las condiciones consideradas representadas por el conjunto de indicadores extraído por la LDA. Aunque se presentaron algunos errores de clasificaciones durante el entrenamiento y prueba del clasificador, estos resultados son prometedores ya que no existe alguna estrategia que se le parezca y sea capaz de evaluar múltiples condiciones de falla a la vez.

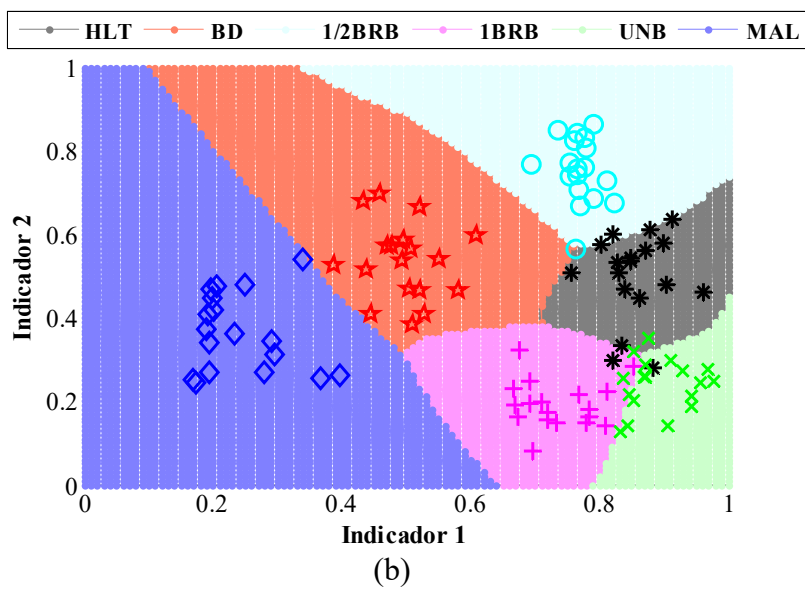



Figura 27. Proyección de las regiones de decisión resultantes del algoritmo de clasificación basado en NN para el conjunto de datos utilizados durante: (a) el entrenamiento de la NN y (b) la prueba de la NN.

Tabla 4.16 Matriz de confusión generada de la evaluación de las condiciones consideradas durante el proceso de entrenamiento del clasificador.

Condición asignada	Condición real					
	HLT	BD	½ BRB	1 BRB	UNB	MAL
HLT	58	0	2	0	3	0
BD	0	70	0	0	0	0
½ BRB	5	0	70	0	0	0
1 BRB	4	0	0	71	14	0
UNB	5	0	0	1	55	0
MAL	0	2	0	0	0	72

Tabla 4.17 Matriz de confusión generada de la evaluación de las condiciones consideradas durante el proceso de prueba del clasificador.

Condición asignada	Condición real					
	HLT	BD	½ BRB	1 BRB	UNB	MAL
HLT	15	0	1	0	1	0
BD	0	18	0	0	0	0
½ BRB	1	0	17	0	0	0
1 BRB	1	0	0	18	3	0
UNB	1	0	0	0	14	0
MAL	0	0	0	0	0	18

#### 4.4 Evaluación de la confiabilidad del diagnóstico de fallas en la cadena cinemática

Como anteriormente se mencionó, para realizar el análisis de la confiabilidad se calculó el coeficiente Alfa de Cronbach ( $\alpha$ ) para las matrices de confusión de los resultados de diagnóstico obtenidos de la evaluación de diferentes condiciones de estado en la caja de engranes y el motor de inducción en las secciones 4.2 y 4.3. Por lo tanto, debido a que los clasificadores que se utilizaron fueron evaluados bajo un sistema de validación cruzada de cinco veces, para cada una de las evaluaciones realizadas se obtuvo el coeficiente  $\alpha$  tanto como para los resultados de diagnóstico y clasificación obtenidos durante el entrenamiento como para los resultados obtenidos durante la prueba. En la Tabla 4.18 se muestra el resumen de los coeficientes de  $\alpha$  obtenidos de evaluar las diferentes matrices de confusión de los resultados de diagnóstico de fallas en la caja de engranes y el motor de inducción. Los valores de  $\alpha$  obtenidos y mostrados en la Tabla 4.18 muestran una excelente estabilidad, incluso todos los valores son mayores al 0.7 que es considerado el punto de corte para considerar que existe buena confiabilidad. Por lo tanto, tanto para el diagnóstico de fallas en la caja de engranes como el motor de inducción se obtuvieron valores del coeficiente  $\alpha$

mayores a 0.93, y esto solo nos dice que los resultados de diagnóstico y clasificación de fallas obtenidos mediante esta metodología son confiables.

Tabla 4.18 Valores del coeficiente de Alfa de Cronbach obtenidos de los resultados de diagnóstico y clasificación de fallas en el motor de inducción.

Iteración	Caja de engranes		Motor de inducción	
	Entrenamiento	Prueba	Entrenamiento	Prueba
1	0.999	0.991	0.989	0.971
2	0.999	1	0.991	0.928
3	0.999	0.991	0.990	0.966
4	0.999	0.981	0.991	0.959
5	0.999	0.991	0.994	0.869
$\bar{x}$	0.999	0.990	0.991	0.938

# Capítulo V

## 5. Conclusiones

En este trabajo se desarrolló una metodología de condición de monitoreo y diagnóstico basadas de fusión de datos y algoritmos inteligentes para la identificación de diferentes condiciones de estado en una cadena cinemática; además, los objetivos e hipótesis planteados determinaron la realización de este trabajo.

Del desarrollo de este trabajo y de los resultados obtenidos hay aspectos importantes que deben mencionarse en relación con el desarrollo de esquemas de condición de monitoreo y diagnóstico aplicado a cadenas cinemáticas. En primer lugar, la consideración de diferentes magnitudes físicas permitirá obtener una mejor caracterización de las diferentes condiciones de estado, y es que ante la aparición de múltiples condiciones de falla una única variable física podría no contener información propia de cada condición. Segundo, el cálculo y la reducción de indicadores son etapas importantes de las estrategias de condición de monitoreo y diagnóstico, esto debido a que a lo largo de estas dos etapas se realiza el procesamiento que va desde calcular un simple indicador estadístico como el RMS, hasta generar un conjunto de indicadores que representen las condiciones de operación de una maquinaria; además, a lo largo de estas etapas no se limita el uso de técnicas de procesamiento de señales, pero hay que resaltar que no siempre aquellas técnicas de procesamiento de señales brindaran los mejores resultados.

En este sentido, hay que resaltar que la inclusión de enfoques híbridos de reducción de indicadores permite obtener un conjunto óptimo de indicadores que mejor describan las condiciones de operación, con estos enfoques se eliminan paso a paso aquellos indicadores que no solo no contienen información relevante, sino que además perjudican el rendimiento de los resultados. Por último, el uso de algoritmos inteligentes, como lo son los clasificadores, les brinda mayor versatilidad a los esquemas de condición de monitoreo y diagnóstico, de hecho, un buen procesamiento de la información les facilitara a los clasificadores la labor de diagnóstico, y bastara usar estructuras de clasificación sencillas para generar respuestas precisas.

Los resultados obtenidos en este trabajo aciertan que el uso de fusión de datos y algoritmos inteligentes incrementa la confiabilidad del diagnóstico de múltiples fallas en una cadena cinemática, estas estructuras de metodologías podrían ser adaptadas en otras aplicaciones para realizar tareas de condición de monitoreo y diagnóstico.



## 6. REFERENCIAS

- Anami, B. S., Pagi, V. B. 2013. Localisation of multiple faults in motorcycles based on the wavelet packet analysis of the produces sounds. *IET Intell. Trans Syst.*, Vol. 7, Iss. 3, pp. 296-304.
- Amarnath, M., Krishan, I. R. P. 2012. Empirical mode decomposition of acoustic signals for diagnosis of faults in gears and rolling element bearing. *IET Sci. Meas. Technol.* Vol. 6, Iss. 4, pp. 279-287.
- Banerjee, T. P., Das, S. 2012. Multi-sensor data fusion using support vector machine for motor fault detection. *Inform. Sciences.* 217:96-107.
- Bediaga, I., Mendizabal, X., Arnaiz, A. and Muñoa J. 2013. Ball bearing damage detection using traditional signal processing algorithms. *IEEE Instru. Meas. Mag.* 16:20-25.
- Bellini, A., Immovilli, F., Rubini, R., y Tassoni, C. 2008. “Diagnosis of bearing faults in induction machines by vibration or current signals: a critical comparison,” *IEEE Industry Applications Society Annual Meeting (IAS '08)*, pp. 1–8.
- Bogiatzidis, I. X., Safacas, A. N. and Mitronikas, E. D. 2013. Detection of backlash phenomena appearing in a single cement kiln drive using the current and electromagnetic torque signatures. *IEEE T. Ind. Electron.* Vol. 60, No. 8, pp 3441-3453.
- Bruton, A., Conway, J. H., Holgate, s. T. 1999. Reliability: What is it, and how is it measured?. *Physiotherapy.* Vol. 86, Iss, 2, pp. 94-99.
- Chen, Z. S., Yang, Y. M. and Hu, Z. 2012. A technical framework and roadmap of embedded Diagnostics and prognostics for complex mechanical systems in prognostics and health management system. *IEEE T. Reliab.* Vol. 61, No. 2, pp314-322.
- Cronbach, L. J. 1951. “Coefficient alpha and the interval structure of tests”, *Psychometrika*, 16, 297–334.
- Delgado-Prieto, M., Cirrincione, G., Garcia Espinosa, A., Ortega, Ja. A., and Henao, H. 2013 “Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks,” *IEEE Transactions on Industrial Electronics*, vol. 30, no. 8, pp. 3398-3407.
- Delgado, M., Urresty, J. C., Alboil, L., Ortega, J. A., Garcia, A., Romeral, L., Vidal, E. 2011. Motor fault classification system including a novel hybrid feature reduction methodology. *IECON 2011-37<sup>th</sup> Annual Conference on IEEE Industrial Electronics Society.* pp. 2388-2393.
- Duda, R. O., Hart, P. E., and Stork, D. G., 2000. “Pattern Classification”, 2nd Edition, Wiley-Interscience.
- Ebrahimi, E., Javadikia, p., Astan, N., Heydari, M., Bavandpour, M., Jalili, M. H., Zarei, A. 2013. Developing an intelligent fault diagnosis of MF285 tractor gearbox using genetic algorithm and vibration signals. *Modern Mechanical Engineering.* 3:152-160.
- Ertunc, H. M., Ocak, H., Aliustaoglu, C. 2013. ANN- and ANFIS-based multi-stage decision algorithm for the detection and diagnosis of bearing faults. *Neural Comp. Appl.* 22:435-446.

- Esfahani, E. T. 2014. 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.
- Gallego, J. T., Castro, F. A. 2011. *La transformada Wavelet aplicada a los sistemas eléctricos de potencia: estado del arte*. Editorial académica de España. ISBN: 3845480874.
- Garcia-Perez, A., Romero-Troncoso, R. J., Cabal-Yepez, E. and Osornio-Rios, R. A. 2011. The application of high-resolution spectral analysis for identifying multiple combined faults in induction motors. *IEEE T. Ind. Electron.* Vol. 58, No. 5, pp. 2002-2011.
- Garcia-Ramirez, A. G., Morales-Hernandez, L. A., Osornio-Rios, R. A., Benitez-Rangel, J. P., Garcia-Perez, A., Romero-Troncoso, R. J. 2014. Fault detection in induction motors and the impact on the kinematic chain through thermographic analysis. *Electr. Pow. Syst. Res.* 114:1-9.
- Garcia-Ramirez, A. G., Osornio-Rios, R. A., Granados-Lieberman, D., Garcia-Perez, A. and Romero-Troncoso, R. J. 2012. Smart sensor for online detection of multiple-combined faults in VSD-Fed induction motors. *Sensors.* 12:11989-12005.
- Granados-Lieberman, D., Romero-Troncoso, R. J., and Osornio-Rios, R. A. 2013. Voltage drop repercussion in industrial processes due to the interaction of several machines in a manufacturing cell. *J. Sci. Ind. Res. India.* Vol. 72, pp. 746-753.
- Henao, H., Kia, S. H. and Capolino, G. A. 2011. Torsional-vibration assessment and gear-fault diagnosis in railway traction systems. *IEEE T. Ind. Electron.* Vol. 58, No. 5, pp. 1707-1717.
- Henao, H., Capolino, G. A., Fernandez-Cabanas, M., Filippetti, F., Bruzzese, C., Strangas, E., Pusca, R., Estima, J., Riera-Guasp, M. and Kia, S. H. 2014. Trends in fault diagnosis for electrical machine; A review of diagnostic techniques. *IEEE Ind. Electron. M.* Vol. 8. Iss. 2, pp. 31-42.
- 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 T. Syst. Man. Cy.* Vol. 44. No. 44, pp. 642-652.
- Huang, N. E., Shen, Z., Long, S. R. 1998, "The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of the Royal Society A*, vol. 454, no. 1971, pp. 903–995.
- Huh, K. K., Lorenz, R. D. and Nagel, N. J. 2012. Gear fault diagnostics integrated in the motion servo drive for electromechanical actuators. *IEEE T. Ind.App.* Vol. 48, No. 1, pp. 142-150.
- Igba, J., Alemzadeh, K., Durugbo, C., and Eriksson, E. T. 2016 "Analyzing RMS and peak values of vibration signals for condition monitoring of wind turbine gearboxes," *Renewable Energy*, vol. 91, pp. 90-106.
- Jauregui-Correa, J. C., and Gonzales, O. M., 2009. "Mechanical vibrations of discontinuous systems", Nova Science, 1st edition.
- Jin, M., Li, R., Xu, Z., Zhao, X. 2014. Reliable fault diagnosis method using ensemble fuzzy ARTMAP based on improved Bayesian belief method. *Neurocomputing.* 133:309-316.

- Kateris, D., Moshou, D., Pantazi, X. E., Gravalos, I., Sawalhi, N. and Loutridis, S. 2013. A machine learning approach for condition monitoring of rotating machinery. *J. Mech. Sci. Technol.* Vol. 28, Iss. 1, pp. 61-71.
- Kohonen, T. 2001. "Self-Organizing Maps", 3th Edition, Springer-Verlag Berlin Heidelberg, ISBN 978-3-540-67921-9.
- Lei, Y., Lin, J., He, Z., Zuo, M. J. 2013. A review of empirical mode decomposition in fault diagnosis of rotating machinery. *Mech. Syst.Signal Pr.* 35:108-126.
- Lei, Y., Zuo, M. J., He, Z., Zi, Y. 2010. A multidimensional hybrid intelligent method for gear fault diagnosis. *Expert Syst. Appl.* 37:1419-1430.
- Li, R. and He, D. 2012. Rotational machine health monitoring and fault detection using EMD-based acoustic emission feature quantification. *IEEE T. Instrum. Meas.* Vol. 61, No. 4, pp. 990-1001.
- Li, R., Seckiner, S. U., He, D., Bechhoefer, E. and Menon, P. 2012. Gear fault location detection for split torque gearbox using AE sensors. *IEEE. T. Syst. Man Cy. C.* Vol. 42, No. 6, 1308-1317.
- Li, W., Zhu, Z., Jiang, F., Zhou, G., and Chen, G. 2015 "Fault diagnosis of rotating machinery with a novel statistical feature extraction and evaluation method," *Mechanical Systems and Signal Processing*, vol. 50-51, pp. 414-426.
- Lin, J., Chen, Q. 2013. Fault diagnosis of rolling bearings based on multifractal detrended fluctuation analysis and Mahalanobis distance criterion. *Mech. Syst.Signal Pr.* 38:515-533.
- Lozano Guzmán, Alejandro A., Jáuregui Correa Juan Carlos A. 2.13. Las vibraciones mecánicas en el mantenimiento predictivo. Primera Edición. Producción FUNDAp. ISBN: 978-607-96048-8-2.
- Mark, W. D., 2015 "Time-synchronous-averaging of gear-meshing vibration transducer responses for elimination of harmonic contributions from the mating gear and the gear pair," *Mechanical Systems and Signal Processing*, vol. 62-63, pp. 21–29.
- Norton, M. P. and Karczub, D. G. 2003. *Fundamentals of noise and vibration analysis for engineers.* Second Edition. Cambridge University Press. ISBN: 978-0-521-49913-2.
- Rao, R. R., Kim, D. N., Hwang, J. J. 2011. *Fast Fourier Transform: Algorithms and Applications.* Springer. ISBN 978-1-4020-6629-0.
- Rao, S. S. 2009. *Engineering Optimization: Theory and Practice.* Fourth Edition. John Wiley & Sons, Inc. ISBN. 978-0-470-18352-6.
- Safizadeh, M. S., Latifi, S. K. 2014. Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell. *Inform. Fusion.* 18:1-8.
- Salah, M., Bacha. K., Chaari., A. 2013. Comparative investigation of diagnosis media for induction machine mechanical unbalance fault. *ISA T.* 52:888-899.
- Seshadrinath, J., Singh, B. and Panigrahi, B. K. 2014. Vibration analysis based on interturn fault diagnosis in induction machines. *IEEE T. Ind. Inform.* Vol. 10, No. 1, pp. 340-350.

- Shatnawi, Y. and Al-khassaweneh, M. 2014. Fault diagnosis in internal combustion engines using extension neural network. *IEEE T. Ind. Electron.* Vol. 61, No. 3, pp. 1434-1443.
- Soualhi, A., Clerc, G. and Razik, H. 2013. Detection and diagnosis of faults in induction motor using an improved artificial ant clustering technique. *IEEE T. Ind. Electron.* Vol. 60, No. 9, pp. 4053-4062.
- Theodoridis, S., and Koutroumbas, K. 2006. "Pattern recognition", 4th Edition, Academic Press, ISBN: 9781597492720.
- Tobon, M. D. A., Medjaher, K., Zerhouni, N. 2012. CNC machine tool's wear diagnostic and prognosis by using dynamic Bayesian networks. *Mech. Syst.Signal Pr.* 28:167-182.
- Tung, T. V., Bo-Suk, Y. 2012. An intelligent condition-based maintenance platform for rotating machinery. *Expert Syst. Appl.* 39:2977-2988.
- Uddin, J., Kang, M., Nguyen, D. V. and Kim, J. M. 2014. Reliable fault classification of induction motors using texture feature extraction and a multiclass support vector machine. *Math. Probl. Eng.* Volume 2014.
- Uicker, J. J., Pennock, G. R, Shigley, J. E. 2011. *Theory of machines and mechanisms.* Fourth Edition. Oxford University Press. ISBN: 0195371232.
- Valtierra-Rodriguez, M., Romero-Troncoso, R. J., Garcia-Perez, A., Granados-Lieberman, D., Osornio-Rios, R. A. 2013 a. Reconfigurable instrument for neural-network-based power-quality monitoring in 3-phase power systems. *IET Gener. Transm. Dis.* Vol. 7, Iss. 2, pp. 1498-1507.
- Valtierra-Rodriguez, M., Romero-Troncoso, R. J., Osornio-Rios, R. A., and Garcia-Perez, A. 2013 b. Detection and classification of single and combined power quality disturbances using neural networks. *IEEE T. Ind. Electron.* Vol. 61, No. 5, pp. 2473-2482.
- van der Maaten, L. J. P. 2007. "An introduction to dimensionality reduction using Matlab", Technical Report, Maastricht University, The Netherlands.
- van der Maaten, L. J. P, Postma, E. O., and van der Herik, H. J. 2008, "Dimensionality reduction: A comparative review", Maastricht University, The Netherlands.
- Van, M., and Kang, H. J. 2015 "Wavelet kernel local Fisher discriminant analysis with particle swarm optimization algorithm for bearing defect classification," *IEEE Transactions on Instrumentation and Measurement*, vol. 64, no. 12, pp. 3358-3600.
- Verucchi, C., Bossio, J., Bossio, G. y Acosta, G. 2016. "Misalignment detection in induction motors with flexible coupling by means of estimated torque analysis and MCSA," *Mechanical Systems and Signal Processing*, vol. 80, pp. 570-581.
- Walker, R. B., Vayanat, R., Perinpanayagam, S., Jennions, I. K. 2014. Unbalance localization through machine nonlinearities using an artificial neural network approach. *Mech. Mach. Theory.* 75:54-66.
- Wang, D., Tse, P. W., Guo, W., and Miao, Q. 2011 a. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis. *Meas. Sci. Tech.* 22:1-13.

- Wang, S., Huang, W., Zhu, Z. K. 2011 b. Transient modelling and parameter identification based on wavelet and correlation filtering for rotating machine fault diagnosis. *Mech. Syst.Signal Pr.* 25:1299-1320.
- Wan, X., Wang, D., Tse, P. W., Xu, G., and Zhang, Q. 2016 “A critical study of different dimensionality reduction methods for gear crack degradation assessment under different operating conditions,” *Measurement*, vol. 78, pp. 138-150.
- Zhang, F., Cai, L., Wang, F., Gao, L., Cui, L. and Liu, Z. 2013 a. Study on calculation methods for sampling frequency of acceleration signals in gear systems. *Adv. Mech. Eng.* Volume 2013.
- Zhang, Z., Wang, Y., Wang, K. 2013 b. Intelligent fault diagnosis and prognosis using wavelet packet decomposition, Fourier transform and artificial neural network. *J. Intell. Manuf.* 2:1213-1227.
- Zhang, X., Zhou, J., 2013. Multi-fault diagnosis for rolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines. *Mech. Syst.Signal Pr.* 41:127-140002E.
- Zappalá, D., Tavner, P. J., Crabtree, C. J., Sheng, S. 2013. Side-band algorithm for automatic wind turbine gearbox fault detection and diagnosis. *IET Renew. Power Gen.* Vol. 8, Iss. 4, pp. 380-389.

## 7. APÉNDICE

### Artículos publicados en revista Indizada JCR (Journal Citation Report)

- 
- 2017 *Diagnosis methodology for identifying gearbox wear based on statistical time feature reduction*; Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, July 2017.  
<https://doi.org/10.1177/0954406217721727>  
Factor de impacto: 1.015.
- 2017 *Multi-fault diagnosis method applied to an electric machine based on high-dimensional feature reduction*; Transactions on Industry Applications IEEE, June 2017. <https://doi.org/10.1109/TIA.2016.2637307>  
Factor de impacto: 2.937.
- 2016 *Vibration-Based Adaptive Novelty Detection Method for Monitoring Faults in a Kinematic Chain*; Shock and Vibration, Hindawi, August 2016.  
<http://dx.doi.org/10.1155/2016/2417856>  
Factor de impacto: 1.281.
- 2016 *Vibration Signal Forecasting on Rotating Machinery by means of Signal Decomposition and Neurofuzzy Modeling*; Shock and Vibration, Hindawi, July 2016. <http://dx.doi.org/10.1155/2016/2683269>  
Factor de impacto: 1.281.
- 2016 *Multiple-Fault Detection Methodology Based on Vibration and Current Analysis Applied to bearings in Induction Motors and Gearboxes on the Kinematic Chain*; Shock and Vibration, Hindawi, February 2016.  
<http://dx.doi.org/10.1155/2016/5467643>  
Factor de impacto: 1.281.

### Artículos de congreso

- 
- 2017 *Diagnosis Methodology Based on Statistical-time Features and Linear Discriminant Analysis Applied to Induction Motors*; The 11th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronic and Drives, SDEMPED 2017. Tinos, Greece.
- 2014 *Reliable methodology for gearbox wear monitoring based on vibration analysis*; The 40th Annual Conference of the IEEE Industrial Electronics Society, IECON' 2014. Dallas, TX-USA.